VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV INFORMATIKY

INSTITUTE OF INFORMATICS

UPLATNĚNÍ STATISTICKÝCH METOD PŘI ZPRACOVÁNÍ DAT

THE USE OF STATISTICAL METHODS FOR DATA PROCESSING

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE Bc. Jiří Čupr

AUTHOR

VEDOUCÍ PRÁCE Mgr. Veronika Novotná, Ph.D.

SUPERVISOR

BRNO 2016

Vysoké učení technické v Brně
Fakulta podnikatelská

Akademický rok: 2015/2016
Ústav informatiky

ZADÁNÍ DIPLOMOVÉ PRÁCE

Čupr Jiří, Bc.

Informační management (6209T015)

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách, Studijním a zkušebním řádem VUT v Brně a Směrnicí děkana pro realizaci bakalářských a magisterských studijních programů zadává diplomovou práci s názvem:

Uplatnění statistických metod při zpracování dat

v anglickém jazyce:

The Use of Statistical Methods for Data Processing

Pokyny pro vypracování:

Úvod
Cíle práce, metody a postupy zpracování
Teoretická východiska práce
Analýza problému
Vlastní návrhy řešení
Závěr
Seznam použité literatury

Seznam odborné literatury:

HINDLS, R. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007. 415 s. ISBN 978-80-86946-43-6.

KROPÁČ, J. Statistika B. 2. dopl. vyd. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2009. 151 s. ISBN 978-80-214-3295-6.

KUBANOVÁ, J. Statistické metody pro ekonomickou a technickou praxi. 3. vyd. Bratislava: STATIS, 2008. 247 s. ISBN 978-80-85659-474.

RŮČKOVÁ, P. Finanční analýza: metody, ukazatele, využití v praxi. 3. rozš. vyd. Praha: Grada, 2010. 139 s. ISBN 978-80-247-3308-1.

SEDLÁČEK, J. Finanční analýza podniku. 1. vyd. Brno: Computer Press, 2007. 154 s. ISBN 978-80-251-1830-6.

Vedoucí diplomové práce: Mgr. Veronika Novotná, Ph.D.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2015/2016.

L.S.

doc. RNDr. Bedřich Půža, CSc.	doc. Ing. et Ing. Stanislav Škapa, Ph.D.
Ředitel ústavu	Děkan fakulty

V Brně, dne 29.2.2016

Abstrakt

Diplomová práce se zabývá problematikou objednávek chlazeného zboží v restauracích McDonald's. Jedná se o analýzu změny spotřeby určitých surovin na základě venkovní teploty. Práce obsahuje teoretická východiska pro správnou analýzu problematiky a samotné zpracování návrhu řešení, kde je zpracovaný algoritmus pro zefektivnění objednávek a snížení nákladů firmy při dodatečném řešení problému s nedostatkem nebo přebytkem surovin. Je zde také představen program napsaný v jazyce VBA, který usnadňuje používání tohoto algoritmu v praxi.

Abstract

This master's thesis is focused on problem of orders of ingredients in McDonald's. It's an analysis of usage changes depending on outside temperature. Thesis includes theoretical background for correct analysis of the problem and possibilities to figuring it out. There is also an algorithmus for more efficient solution of problem with needs or excess of ingredients. There is also a program written in VBA language, that makes more simple usage of this algorithm on restaurants.

Klíčová slova

tržba, teplota, spotřeba, korelace, regresní analýza, test statistických hypotéz, Kendallovo tau, Pearsonův korelační koeficient, budoucí spotřeba

Key words

sales, temperature, usage, correlation, regression analysis, hypothesis testing static, Kendall's tau, pearson's correlation coefficient, future usage

Bibliografická citace

ČUPR, J. *Uplatnění statistických metod při zpracování dat.* Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2016. 103 s. Vedoucí diplomové práce Mgr. Veronika Novotná, Ph.D.

Čestné prohlášení

Prohlašuji, že předložená diplomová práce je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušil autorská práva (ve smyslu Zákona č. 121/2000 Sb., o právu autorském a o právech souvisejících s právem autorským).

V Brně dne 26. 5. 2016

Podpis

Poděkování

Tímto bych chtěl poděkovat vedoucí práce paní Mgr. Veronika Novotná, Ph.D. za cenné rady a připomínky v průběhu zpracování diplomové práce a především trpělivost, kterou se mnou měla.

Také bych chtěl poděkovat vedení společnosti Baierová spol. s.r.o. za poskytnutí vstupních dat a za podporu při zpracování praktické části.

Obsah

ÚVOD

V diplomové práci se zabývám analýzou a optimalizací zboží v McDonald’s, který má nízkou dobu trvanlivosti. Jedná se o tzv. chlazené zboží, především zelenina a mléko. Kvůli nízkému krytí dob spotřeby mezi dodávkami se velice často stává, že se musí zboží, které již překonalo dobu spotřeby, vyhodit a firmě tak vznikají nemalé náklady. Naopak se také stává, že zboží je před další dodávkou nedostatek a musí se vypůjčit z jiné restaurace, což opět stojí firmu peníze na benzín, auto a mzdu zaměstnance.

V teoretické části proberu statistické metody, které budou uplatněné v dalších částech diplomové práce.

V analytické části proběhne podrobné seznámení s problémem objednávek chlazeného zboží a budu zjišťovat vliv venkovní teploty na návyky zákazníků a tím tedy i spotřebu tohoto zboží. Jako období pro analýzu jsem vybral letní měsíce roku 2015, protože v této době jsou nejen největší tržby, ale také spotřeba chlazeného zboží a jeho špatné objednávání se tak nejvíce projeví do nákladů právě v tomto období.

V řešitelské části využiji údaje zjištěné z analýzy a navrhnu speciální výpočet pro větší efektivitu objednávek a tím snížení nákladů na vyhozené zboží nebo na zajišťování zboží.

Výstupem diplomové práce také bude program v Excelu napsaný pomocí VBA, který bude jednoduše použitelný ve firmě a pomůže tak i řadovým manažerům s efektivním objednáváním chlazeného zboží.

Cíl práce

Cílem práce je po analýze dat, jestli má venkovní teplota vliv na spotřebu určitých suroviny, navrhnout takové řešení objednávání zboží, které zmenší náklady na pořízení chybějících surovin nebo naopak na vyhozené zboží.

Spotřeba chlazeného zboží bývá proměnlivá a vliv na to by měla mít venkovní teplota. Jelikož firma každý týden spotřebuje toto zboží za statisíce Kč, je zde tlak na jeho správné objednávání. Avšak ani po několikaletých zkušenostech s objednávkami se často nedaří objednat přesně takové množství zboží, aby se vešlo často do malého časového okna mezi další dodávkou a dobou spotřeby suroviny. Pomocí statistických metod lze zjistit spojitost mezi teplotou a spotřebou a na základě předpovědi počasí tak určit její pravděpodobnou spotřebu v budoucnu. Díky tomu lze dosáhnout tolik požadované snížení nákladů.

Mezi hlavní výstup diplomové práce patří program v Excelu, který bude uživatelsky příjemný, bude v sobě integrovat potřebné statistické funkce a manažerovi, který bude chlazené zboží objednávat, doporučí na základě zadaných vstupních dat množství suroviny, které má objednat.

1 TEORETICKÁ ČÁST

1.1 Druhy rozdělení dat

Náhodná veličina je základní prostor *Ω* vytvořený výsledky určitého pokusu. Náhodná veličina, kterou označíme *X*, je funkce, která prvkům ω tohoto základního prostoru *Ω* přiřazuje reálná čísla *x*, kde x = *X(ω)*.

Náhodná veličina *X* je diskrétní, jestliže prvky základního prostoru *Ω* zobrazí na osu reálných čísel jako izolované body, označené $x_1, x_2, \ldots, x_k$, přičemž každý z těchto bodů má nenulovou pravděpodobnost.

Náhodná veličina *X* je spojitá, jestliže její hodnoty, přiřazené prvkům základního prostoru *Ω*, tvoří interval na ose reálných čísel, přičemž každý bod tohoto intervalu má nenulovou pravděpodobnost.

Pravěpodobnostním zákonem, který se používá k popisu chování spojité náhodné veličiny je hustota pravděpodobnosti, označovaná *f(x)*, které charakterizuje „nahuštěnost“ hodnot spojité náhodné veličiny *X* na ose reálných čísel v okolí bodu *x*.

Touto funkcí se dá znázornit několik typu rozdělení dat, například rovnoměrné, normální, exponenciální, logaritmické. Níže je popsáno jedno ze základních rozložení, normální a nenormální. (1, str. 32-33)

1.1.1 Normální rozdělení

Normální rozdělení je označované také jako Gaussovo normální rozdělení. Spojitá náhodná veličina *X* má náhodné rozdělení s parametry střední hodnotou μ a směrodatnou odchylkou σ, což označujeme $N(\mu,\sigma^2)$, jestliže její hustota pravděpodobností *f(x)* je dána následujícím předpisem:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \tag{1.1}$$

Grafické znázornění normálního rozdělení vypadá následovně.

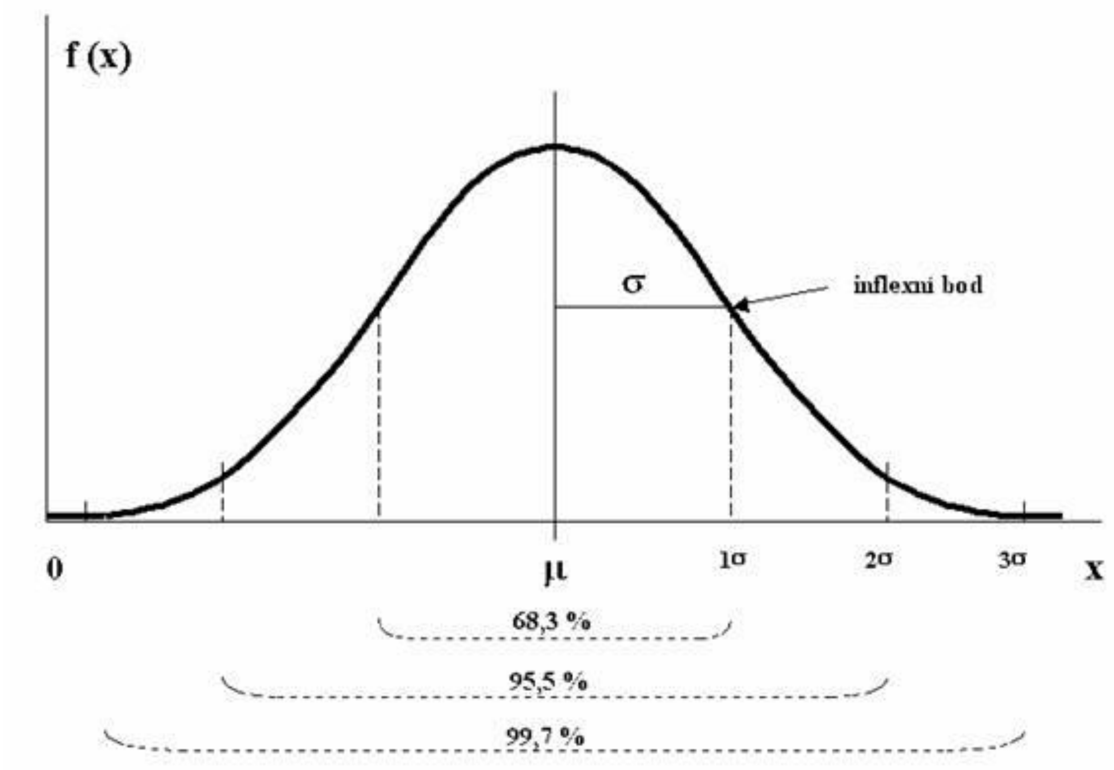

Obrázek 1: Grafické znázornění normálního rozdělení
Zdroj: (2)

Křivka, představující hustotu pravděpodobnosti *f(x)* normálního rozdělení se nazývá Gaussova křivka. Jejími charakteristickými rysy je to, že je symetrická kolem svislé přímky procházející bodem μ, v němž má funkce *f(x)* globální maximum, v bodech μ - σ a $\mu + \sigma$ má inflexní body a ve vzdálenostech 3σ vlevo a vpravo od bodu μ se téměř dotýká osy x.

Normální rozdělení je nejdůležitějším spojitým rozdělením, protože jej mají mnohé náhodné veličiny. Obecně lze říci, že je použitelné všude tam, kde hodnoty náhodné veličiny jsou ovlivněny působením velkého počtu nepatrných, vzájemně nezávislých nebo slabě závislých náhodných vlivů. (1, str. 62-63)

Při statistické analýze bývá normalita rozdělení podmínkou použití těch nejúčinnějších statistických metod. (2)

1.1.2 Nenormální rozdělení

Nenormální rozdělení, také neznámé rozdělení, je také, které neodpovídají Gaussovu normálnímu rozdělení pravděpodobností – mají pak obvykle různě nepravidelnou křivku rozdělení, často vícevrcholovou a asymetrickou. Hovoříme o tzv. neznámém rozdělení pravděpodobností, které pro nepravidelnost křivky nelze popsat přesnými parametry, určujícími střed symetrie ani šířku křivky, jako tomu bylo u Gaussova normálního rozdělení.

Pro popis neznámého rozdělení je používána jediná charakteristika – medián. Medián je považován za střed neznámého rozdělení, šířku křivky neznámého rozdělení nelze pro její nepravidelnost určovat. Protože je medián definován jako 50 % kvantil, dělí plochu pod křivkou rozdělení na 2 poloviny, symbolicky znázorňující podíl jedinců (50 %) v populaci, kteří mají hodnoty sledovaného znaku nižší než medián a podíl jedinců (50 %) v populaci, kteří mají hodnoty sledovaného znaku vyšší než medián. (2)

Níže jsou dvě znázornění možného průběhu funkce *f(x)* nenormálního rozdělení.

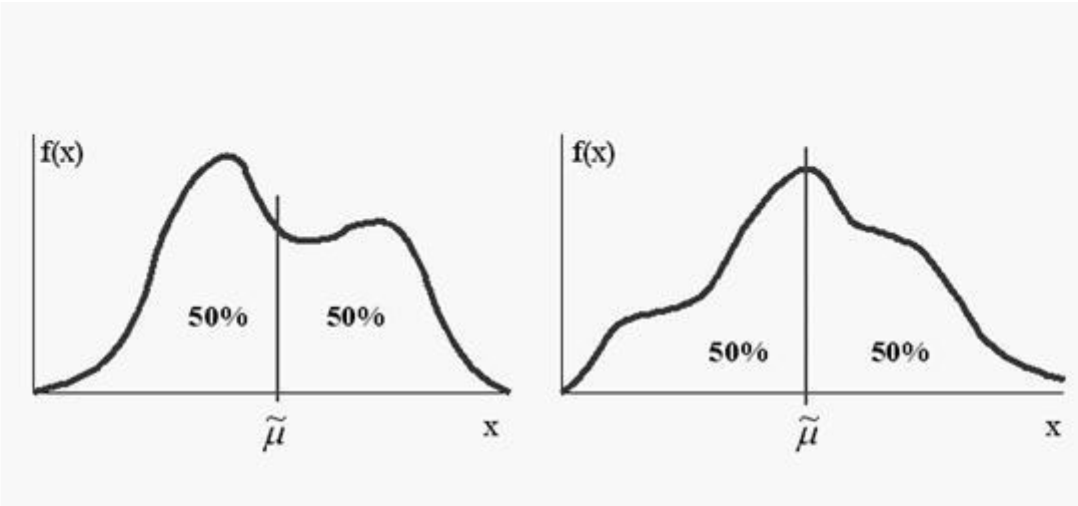

Obrázek 2: Grafické znázornění nenormálního rozdělení
Zdroj: (2)

1.1.3 Test normality

Testy normality slouží k otestování souboru hodnot, zda mají normální rozdělení. Testuje se statistická hypotéza dle zvoleného testu a na jeho základě se rozhodne o přijetí/nepřijetí testu na určité hladině významnosti. Pro test normality si volím Shapirův-Wilkův test normality.

Shapirův-Wilkův test se ve statistice používá pro testování hypotézy, která tvrdí, že náhodný výběr $x_1, \ldots x_n$ pochází z normálního rozložení s blíže nespecifikovanými parametry μ a σ^2, $N(\mu, \sigma^2)$. Tento test je založen na zjištění, zda se body sestrojeného kvantil-kvantilového grafu (Q-Q plotu) významně liší od regresní přímky proložené těmito body.

Testová statistika má tvar:

$$W = \frac{b^2}{S^2} = \frac{\left(\sum_{i=1}^{k} a_{n-i+1}(y_{n-i+1} - y_i)\right)^2}{\sum_{i-1}^{n}(y_i - \bar{y})^2} \tag{1.2}$$

kde y_i jsou uspořádané hodnoty náhodného výběru $x_1, \ldots, x_n$, a_{n-i+1} jsou tabelizované váhy, y je výběrový průměr a $k = n/2$, je-li n sudé, resp. $k = (n-1)/2$, je-li n liché. Čím více se hodnota testové statistiky blíží číslu 1, tím je lepší shoda mezi teoretickým a empirickým rozložením. Z toho plyne, že pokud hodnota testové statistiky nepřekročí tabelovanou kritickou hodnotu Shapiro-Wilkova testu, nulovou hypotézu zamítáme na dané hladině významnosti. (3, str. 18)

1.2 Testy statistických hypotéz

Statistickou hypotézu nazýváme tvrzením, týkajících se parametrů nebo tvaru rozdělení znaku *X*, definovaného na prvcích základního souboru. Testem statistických hypotéz rozumíme postup, pomocí něhož na základě informací, získaných z datového souboru, rozhodujeme o tom, zda statistickou hypotézu přijmeme nebo odmítneme. Nulová hypotéza je tvrzení, o kterém pomocí testu rozhodujeme, zda-li ho přijmeme nebo zamítneme. Značí se jako H_0. Proti nulové hypotéze stavíme alternativní hypotézu značenou H_1, která značí její negaci.

Při testu statistické hypotézy dodržujeme následující postup:

1. Formulujeme nulovou *hypotézu H_0 a k ní alternativní hypotézu H_1.*

2. *K testování nulové hypotézy H_0 použijeme náhodnou veličinu označenou G, která je funkcí náhodného výběru X, a nazveme jí testovým kritériem. Z datového souboru x vypočteme její realizovatelnou hodnotu označenou* g.

3. Ke zvolenému číslu α (volíme buď 0,01 nebo 0,05), které se nazývá hladinou významnosti, určíme tzv. kritický obor $W_α$, v němž se při platnosti hypotézy H_0 realizuje nejvýše 100 α % hodnot testového kritéria G.

4. Podle toho, jak se realizuje testové kritérium G v kritickém oboru, přijmeme následující rozhodnutí:

a) Když g $\in W_α$, pak řekneme, že zamítáme nulovou hypotézu ve prospěch alternativní hypotézy.

b) g $\notin W_α$, pak řekneme, že přijmeme nulovou hypotézu.

Rozhodnutí, která jsou uvedená ve čtvrtém bodě, jsou podložena následující úvahou:

Kritický obor $W_α$ je taková množina, v níž se hodnoty náhodné veličiny G, za předpokladu, že platí nulová hypotéza H_0, vyskytují s velmi malou pravděpodobností α. Pokud je náhodná veličina G v kritickém oboru realizovala, pak nastal jev, který při platnosti nulové hypotézy má velmi malou pravděpodobnost. Tedy předpoklad, že platí hypotéza H_0 zamítáme a přijmeme alternativní hypotézu H_1. Přijmutí nulové hypotézy však znamená jen to, že tato hypotéza nebyla vyvrácena a že jsme tedy pouze oprávněni ji podržet. Není to důkaz její pravdivosti. (4, str. 30)

1.3 Regresní analýza

V ekonomice a přírodních vědách se často pracuje s proměnnými veličinami, kdy mezi nezávisle proměnnou, označenou *x*, a závisle proměnnou, označenou *y*, kterou měříme či pozorujeme, existuje nějaká závislost. Ta je buď vyjádřena funkčním předpisem $y = φ(x)$, kde ale funkci $φ(x)$ neznáme nebo tuto závislost nelze „rozumnou“ funkcí vyjádřit. Víme jen, že při nastavení určité hodnoty nezávisle proměnné *x*, dostaneme jednu hodnotu závisle proměnné *y*.

Měříme, resp. pozorujeme hodnoty závisle proměnné, označené y, při nastavených hodnotách nezávislé proměnné, označené *y*. Po provedení měření dostaneme *n* dvojic (x_i, y_i), kde $i = 1, 2, …, n$, přičemž $n > 2$, kde x_i určuje předem nastavenou hodnotu nezávisle proměnné x v i-tém pozorování nebo měření a y_i k ní přiřazenou hodnotu závisle proměnné y.

Avšak působením různých náhodných vlivů a neuvažovaných činitelů, nazývaných šum, nedostaneme při opakování pozorování při nastavené hodnotě proměnné x tutéž hodnotu proměnné y, ale obecně jinou její hodnotu. Jestliže bychom pozorování při stejně nastavené hodnotě x opakovali, pak bychom dostávali různé hodnoty y. Tedy proměnná y se chová jako náhodná veličina, kterou označujeme Y.

Závislost mezi x a y je tedy ovlivněna šumem, což je náhodná veličina, která vyjadřuje vliv náhodných a neuvažovaných činitelů. Tuto náhodnou veličinu označíme jako e. Předpokládá se u ní, že její střední hodnota E(e) = 0, což značí, že při měření se nevyskytují systematické chyby a výchylky od skutečné hodnoty, které jsou způsobené šumy, jsou rozloženy kolem ní jak v kladném, tak v záporném smyslu.

Abychom závislost náhodné veličiny Y na proměnné x vyjádřili, je zavedena podmíněná střední hodnota náhodné veličiny Y pro hodnotu x, označovanou E(Y|x) a pokládáme ji rovnu vhodně zvolené funkci, kterou označíme $\eta(x;\beta_1,\beta_2,\dots,\beta_p)$*, pro zjednodušení použijeme zkráceně* $\eta(x)$*. Vzorec pro vztah střední hodnoty* $E(Y|x)$ *funkce* $\eta(x)$ *lze zapsat takto:*

$$E(Y|x) = \eta(x;\beta_1,\beta_2,\dots,\beta_p) \tag{1.3}$$

Funkce $\eta(x)$ *se nazývá regresní funkcí a je funkcí proměnné x a obsahuje neznámé parametry, označené* $\beta_1, \beta_2, \dots, \beta_p$, kde $p \geq 1$, *ty nazýváme regresními koeficienty. Pokud funkci* $\eta(x)$ *pro zadaná data určíme, pak říkáme, že jsme zadaná data vyrovnali regresní funkcí. Úlohou regresní analýzy je zvolit pro zadaná data* (x_i, y_i), $i = 1,2,\dots,n$, *vhodnou funkci* $\eta(x)$ *a odhadnout její koeficienty tak, aby vyrovnání hodnot* y_i *touto funkcí bylo co nejlepší.* (4, str. 78-79)

1.3.1 Regresní přímka

Nejjednodušší případ regresní úlohy je, pokud je regresní funkce $\eta(x)$ vyjádřena přímkou $\eta(x) = \beta_1 + \beta_2 x$, potom platí:

$$E(Y|x) = \eta(x) = \beta_1 + \beta_2 x \tag{1.4}$$

Náhodnou veličinu Y_i, příslušnou nastavené proměnné x_i, lze tudíž vyjádřit jako součet funkce $\eta(y)$ a šumu e_i, pro úroveň x_i.

Odhady koeficientů β_1 a β_2 regresní přímky pro zadané dvojice (x_i, y_i) označíme b_1 a b_2. K určení těchto koeficientů, které mají být co nejlepší, použijeme metodu nejmenších čtverců. Tato metoda spočívá v tom, že za nejlepší považujeme koeficienty b_1 a b_2, minimalizující funkci $S(b_1, b_2)$ (4, str. 80).

Funkce $S(b_1, b_2)$ je tedy rovna součtu kvadrátů odchylek naměřených hodnot y_i od hodnot $\eta_i = \eta(x_i) = b_1 + b_2 x_i$ na regresní přímce. Hledané hodnoty b_1 a b_2 a koeficientů β_1 a β_2 regresní přímky pro zadané dvojce (x_i, y_i) určíme tak, že vypočteme první parciální derivace funkce $S(b_1, b_2)$ podle proměnných hodnot b_1, resp. b_2 a získané parciální derivace položíme rovny nule. Poté rovnice upravíme a vyjádříme b_2 a b_1 dle následujícího vzorce:

$$b_2 = \frac{\sum_{i=1}^{n} x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^{n} x_i^2 - n\bar{x}^2}, b_1 = \bar{y} - b_2\bar{x} \tag{1.5}$$

$\bar{x}$ a $\bar{y}$ jsou výběrovými průměry, pro něž platí:

$$\bar{x} = \frac{1}{n}\sum_{i=1}^{n} x_i, \bar{y} = \frac{1}{n}\sum_{i=1}^{n} y_i \tag{1.6}$$

Odhad regresní přímky je potom dán předpisem:

$$\hat{\eta}(x) = b_1 + b_2 x \tag{1.7}$$

(2, str. 81-82)

Vlastnosti koeficientu regresní přímky

Protože koeficienty regresní přímky b_1 a b_2 vychází z naměřených hodnot závisle proměnné y_i, jejíž hodnoty se při opakování měření mění, tak v případě kdy budeme měření opakovat vícekrát, dostaneme vždy obecně jiné hodnoty y_i a tudíž i jiné hodnoty koeficientů b_1, b_2 a jinou regresní přímku. Z toho vyplívá, že vypočtené regresní koeficienty a regresní přímka jsou náhodnými veličinami B_1, B_2 a $\hat{\eta}(x)$, jež nazveme statistikami.

Je potřeba uvést další předpoklady o vlastnostech náhodných veličin e_i, představující šumy, které ovlivňují hodnoty závislé proměnné. Tyto předpoklady vyjadřují, že náhodné veličiny e_i mají nulové střední hodnoty a také rozptyl σ^2, což prakticky značí, že měření závislé proměnné není zatíženo systematickými chybami a rozptyly chyb měření jsou nezávislé na jednotlivých hodnotách nezávislé proměnné. Poslední z těchto předpokladů vyjadřuje, že kovariace náhodných veličin e_i, e_j, kde i není rovno j, je rovno nule, tedy tyto náhodné veličiny jsou nekorelované, což značí, že mezi nimi není lineární korelační vazba.

Pokud jsou předpoklady splněny, tak platí, že střední hodnoty náhodných veličin Y_i jsou rovny hodnotám regresní přímky, jejich rozptyl je stejný jako rozptyl náhodných veličin e_i a náhodné veličiny Y_i a Y_j, kde $i \neq j$, jsou nekorelované.

Díky výše uvedeným podmínkám lze odvodit, že pro střední hodnoty statistik B_1 a B_2 platí, že jsou nestrannými bodovými odhady koeficientů β_1 a β_2. To značí, že když vypočteme uvedené koeficienty pro několik sérií měření veličin y, pak průměry získaných regresních koeficientů jsou rovné regresním koeficientům β_1 a β_2.

Jsou-li splněny předpoklady o vlastnostech náhodných veličin e_i, pak je rozptyl

statistiky B_2 dán vzorcem:

$$D(B_2) = \frac{\sigma^2}{\sum_{i-1}^{n} x_1^2 - n\bar{x}^2} \qquad (1.8)$$

Hodnota rozptylu σ^2 charakterizuje přesnost měření. Pokud tato hodnota není zadána, lze ji odhadnout pomocí tzv. reziduálního součtu čtverců, označeným S_R, který se rovná součtu kvadrátů reziduí $\hat{e}_i$, jež vyjadřují odchylky zadaných hodnot y_i od hodnot regresní přímky $\widehat{D}(B_2)$.

$$S_R = \sum_{i=1}^{n} (y_i - \hat{n}(x_i))^2 \qquad (1.9)$$

Reziduální součet čtverců charakterizuje stupeň rozptýlení pozorovaných hodnot závisle proměnné kolem určené regresní přímky. Odhad rozptylu σ^2, označený $\hat{\sigma}^2$, je pak roven:

$$\hat{\sigma}^2 = \frac{S_R}{n-2} \quad , \qquad (1.10)$$

kde n je počet naměřených dvojic (x_i, y_i).

Po dosazení odhadu rozptylu $\hat{\sigma}^2$ *do vzorce (1.8) dostaneme odhad rozptylu označeného* $\hat{D}(B_2)$. (4, str. 83-84)

Intervaly spolehlivosti pro regresní přímku

Jestliže k předpokladům o vlastnostech náhodných veličin e_i, *přidáme další předpoklad, že rozdělení náhodných veličin* e_i *je normální, pak statistiky mají Studentovo rozdělení o n-2 stupních volnosti a můžeme pomocí nich testovat hypotézy o jednotlivých parametrech* β_1, β_2.

$$T_{B_l} = \frac{B_l - \beta_l}{\sqrt{\hat{D}(B_l)}}, kde\ l = 1{,}2 \tag{1.11}$$

(2, str. 85)

1.4 Korelace

Statistická analýza se zřídka zabývá pouze jednou izolovanou proměnnou. Často se zajímáme o srovnání několika rozdělení, o změny proměnné v čase nebo vztahy mezi proměnnými. K jejich analýze používáme statistické metody. Příslušná oblast se nazývá korelační analýza a do metod je možné zahrnou také regresní analýzu.

Korelační analýza zkoumá vztahy proměnných graficky a pomocí různých měr závislosti, které nazýváme korelační koeficienty. V nejobecnějším smyslu slovo „korelace“ označuje míru stupně asociace dvou proměnných. Říká se, že dvě proměnné jsou asociované (proměnné), jestliže určité hodnoty jedné proměnné mají tendenci se vyskytovat společně s různými hodnotami druhé proměnné. Míra této tendence může sahat od neexistující korelace až po absolutní korelaci.

Pro měření korelace byla navržena řada koeficientů. Liší se podle typu proměnných, pro které se využívají. Při zkoumání korelačních vztahů má rozhodující význam kvalitativní rozbor příslušného materiálu. Nemá smysl měřit korelaci tam, kde na základě logické úvahy nemůže existovat. (5, str. 247)

1.4.1 Pearsonův korelační koeficient

Přes některé nedostatky zůstává Pearsonův korelační koeficient r nejdůležitější mírou síly vztahu dvou náhodných spojitých proměnných *X* a *Y*. Počítáme jej z n párových hodnot $\{(x_i, y_i)\}$ změřených na n jednotkách náhodně vybraných z populace. Korelační koeficient nabývá hodnot z intervalu [-1;1].

Korelační koeficient r počítáme pomocí kovariace s_{xy} a směrodatných odchylek s_x a s_y obou proměnných:

$$s_{xy} = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y}}{n-1} \tag{1.12}$$

$$r_{xy} = \frac{s_{xy}}{s_x s_y} \tag{1.13}$$

Vzorec s kovariací pomáhá porozumět tomu, že r má kladnou hodnotu, pokud je asociace proměnných pozitivní. Proměnná Y se zvětšuje se zvyšováním proměnné X. Naopak pokud má r zápornou hodnotu, je asociace proměnných záporná a proměnná Y se zmenšuje se zvyšováním proměnné X.

(5, str. 253)

1.4.2 Kendalovo Tau

Korelační koeficient má měřit „sílu vztahu“ dvou proměnných, ale různé korelační koeficienty ho měří různým způsobem. Kendallův korelační koeficient má na rozdíl od Pearsonova korelačního koeficientu jednoduchou pravděpodobnostní interpretaci. Jeho teoretickou hodnotu v populaci označujeme τ_k nebo Kendallovo tau.

Kendall založil svoji statistiku na inverzích v pořadí. Vycházíme z dat, které se týkají metrického nebo ordinálního hodnocení *n* objektů ($i = 1, 2, \ldots, n$) podle dvou kritérií *X* a *Y*. Ke každému objektu i získáme ohodnocení (x_i, y_i). Nejdříve seřadíme dvojice (x_i, y_i) tak, že hodnoty x_i budou tvořit rostoucí posloupnost. Jestliže je mezi kritérii X a Y kladná asociace, pak také y_i budou mít vzestupnou tendenci. Při záporné asociaci budou mít y_i sestupnou tendenci.

Rozlišujeme zde konkordance, jež skóruje pro kladnou asociaci a diskordance, která skóruje pro negativní asociaci. Počet všech konkordancí, resp. diskordancí označíme P, resp. Q. Rozdíl S = P – Q je jednoduchou mírou závislosti. Převaha konkorancí, resp.

diskordancí vede ke kladné, resp. záporné hodnotě S. Kendallův koeficient tau τ_k *se počítá podle vzorce:*

$$\tau_k = \frac{S}{D} = \frac{P-Q}{D} \qquad (1.14)$$

, kde D je maximální možná počet konkordancí, resp. diskordancí a vypočítá se následovně:

$$D = \frac{n(n-1)}{2} \qquad (1.15)$$

Hodnotu Kendallova tau interpretujeme tak, že u dvou náhodně vybraných jedinců můžeme očekávat s pravděpodobností τ_k*, že jejich seřazení podle kritéria X bude stejné jako seřazení podle kritéria Y.* (5, str. 271)

1.5 Testy rozdílu středních hodnot dvou souborů

Cílem statistického usuzování je porovnat odpovědi na dvě různá ošetření nebo intervence nebo porovnat dvě populace. Z každé populace máme zvláštní výběr. Porovnáme průměry μ_1 *a* μ_2 *sledované proměnné. Zajímá nás, zda rozdíl průměrů má určenou hodnotu* Δ*, nebo se od ní liší.* (5, str. 217)

1.5.1 Studentův t-test

Studentův t-test je nejčastěji používaným parametrickým testem - používá se pro testování rozdílu 2 středních hodnot μ*. Podle statistické významnosti testovaného rozdílu středních hodnot (nejčastěji mezi pokusnou a kontrolní skupinou) usuzujeme na účinnost aplikovaného pokusného zásahu ve sledovaném experimentu.*

Výpočet testovacího kritéria t vychází z odhadů parametrů μ *a* σ^2 *u výběrových souborů* $\bar{x}$ *a* s^2*. Vypočtené testovací kritérium porovnáme s tabulkovou kritickou hodnotou (1-* α */2 kvantil Studentova t-rozdělení pro dané* ν *a zvolené* α*).* (6)

Dvojvýběrový párový t-test

Dvojvýběrový párový t-test se používá pro hodnocení experimentů, kde neznáme střední hodnotu základního souboru, a porovnáváme pouze 2 soubory výběrových dat. Tato data mohou být představována buď dvěma měřeními provedenými opakovaně u jedné skupiny jedinců (typicky měření před aplikací pokusného zásahu a po aplikaci – tzv. „párový pokus“ neboli „závislé výběry“) nebo dvěma nezávislými skupinami měření („nepárový pokus“ neboli „nezávislé výběry“).

V případě dvojvýběrového t-testu testujeme nulovou hypotézu: $H_0 : \mu_1 = \mu_2$.

Párový t-test porovnává data, která tvoří „spárované variační řady“, tzn. že pocházejí ze subjektů, které byly podrobeny dvěma měřením. Provádíme tedy 2 měření u jednoho výběrového souboru: 1. měření před aplikací pokusného zásahu, 2. po aplikaci pokusného zásahu. Takto získané hodnoty tvoří páry a reprezentují při testování jak kontrolní tak i pokusnou skupinu porovnávaných dat.

V testu vycházíme z rozdílů naměřených párových hodnot u srovnávaných variačních řad. Testujeme hypotézu, že střední hodnota měření před pokusem a po pokuse se rovnají (rozdíl středních hodnot párových měření je nulový).

Nejprve vypočteme rozdíly párových hodnot u výběrového souboru (n - počet párů) a ze zjištěných rozdílů vypočítáme aritmetický průměr $\bar{x}$ a směrodatnou odchylku s (resp. rozptyl s^2).

Poté vypočteme testovací kritérium:

$$t = \frac{|\bar{x}|}{\sqrt{\frac{s^2}{n}}} \tag{1.16}$$

Pro vyhledání tabulkové kritické hodnoty je nutno stanovit počet stupňů volnosti výběrového souboru: $v = n-1$ a zvolit hladinu významnosti α.

Vypočtenou statistiku t porovnáme s tabulkovou kritickou hodnotou $t_{1-\alpha/2(v)}$, kde $v = n-1$ a α volíme 0,05 nebo 0,01.

Je-li $t \leq t_{1-\alpha/2(v)}$, tak je statisticky nevýznamný rozdíl μ_1 a μ_2 při zvolené α. Nezamítáme nulovou hypotézu H_0, tzn., že střední hodnota měření před pokusem se neliší od střední hodnoty měření po pokusu.

Je-li $t \geq t_{1-\alpha/2(v)}$, tak je statisticky významný rozdíl μ_1 a μ_2. Zamítáme nulovou hypotézu H_0, tzn., že střední hodnota měření před pokusem se liší od střední hodnoty měření po pokusu. (6)

1.5.2 Wilcoxonův párový test

Studentův t-test předpokládá normální rozdělení proměnné v populaci. Protože v mnoha *situacích je tato podmínka omezující, statistici vyvinuli alternativní postupy s méně přísnými předpoklady. Neparametrické testy lze použít za obecnějších podmínek.*

Wilcoxonův párový test vychází z pořadí údajů a ze skutečnosti, že větší naměřené hodnoty mají vyšší pořadí. Jestliže tedy v jedné skupině máme více větších pozorování, průměrná hodnota pořadí bude větší, než ve druhé skupině. (5, str. 239)

Postup pro výpočet je následující:

1) Zjistíme rozdíly mezi párovými hodnotami (veličina Z) – některé rozdíly jsou kladné, jiné záporné a v případě shody párových hodnot jsou rozdíly nulové). Nulové rozdíly z dalšího hodnocení vyřazujeme.

2) Nenulové rozdíly uspořádáme vzestupně bez ohledu na znaménko.

3) Každému rozdílu přiřadíme pořadí.

Testujeme hypotézu, že rozdíly jsou rozloženy symetricky kolem 0, tzn., že součet kladných a záporných rozdílů by měl být roven 0 (v případě, že platí shoda rozdělení obou veličin X a X′). Proto by se také neměl příliš lišit součet pořadí kladných a záporných rozdílů.

4) Označíme:

W_+ *- součet pořadí odpovídajících kladným rozdílům*

W_- *- součet pořadí odpovídajících záporným rozdílům*

Platí, že $W_+ + W_- = \frac{n*(n+1)}{2}$

Menší z obou součtů W_+ a W_- *použijeme jako testovací kritérium.*

5) Porovnáme vypočtené testovací kritérium W s tabelovanou kritickou hodnotou pro příslušné n a zvolenou hladinu významnosti α.

Kritické hodnoty pro Wilcoxonův test:

Je-li $W < W(\alpha, n)$*, zamítáme hypotézu o shodnosti rozdělení veličiny X a X′ tj. symetrického rozložení + a - rozdílů párových hodnot, tj. že* hodnoty *se liší ve svém rozdělení.*

Je-li W > W(α, n), nemůžeme zamítnout hypotézu o shodnosti rozdělení veličiny X a X′, tj. symetrického rozložení + a - rozdílů párových hodnot, tj. hodnoty se neliší ve svém rozdělení). (7)

1.6 Visual Basic for Applications

Visual Basic je programovací jazyk vytvořený společností Microsoft. Pracuje v operačním prostředí Windows. Jako editor použiji vestavěný editor v Excelu.

Využiji následující prvky:

- Userform – formuláře pro zobrazení dalších prvků, funkčních tlačítek a dat
- Command Button – tlačítko pro vykonání akce
- Label – zobrazuje pouze text, nevykonává žádnou akci
- Textbox – okno pro vložení dat
- Option Button – přepínač mezi několika možnostmi

Pro samotné programování jsem využil především základních matematických operací. Pro uložení do buňky je použita syntaxe:

Range("buňka").Value = číslo

2 ANALÝZA PROBLÉMU

2.1 Seznámení s firmou

Název společnosti: Baierová spol. s.r.o.

IČO: 47904534

Právní forma: společnost s ručením omezeným

Datum vzniku: 7. 1. 1993

Počet zaměstnanců: 250 - 499

Základní kapitál: 100 000Kč

Jednatel: Renata Roubínková Baierová

Společnost začala podnikat v roce 1995 díky franšízové smlouvě s jednou restaurací McDonald's a to v Líšni v Brně. Záhy přibyla restaurace na odpočívadle Rohlenka a v roce 1997 také v Brně M-paláci (8). V roce 1998 byla další restaurace otevřena v novém nákupním centru Avion Shopping Park na dálnici D2 (9). V roce 1999 poté bylo otevřené nové centrum na dálnici D2 Olympia (10). V roce 2001 se z důvodu nízkých tržeb a špatného odhadu profitability místa zavřela provozovna v Líšni (11) a vybavení se přesunulo do nového obchodního centra Futurum (12). Zde provozovna vydržela pouze do roku 2005, kdy byla také z důvodu nízkých tržeb uzavřena a vybavení přesunuto do nového nákupního střediska v centru Brna - Galerie Vaňkovka. Tato provozovna stále funguje, a ani není důvod k jejímu přesunu nebo zrušení. V květnu toku 2012 byla zakoupena licence na provozovnu v centru Jihlavy. Tato restaurace nebyla nově otevřena, pouze byla na základě franšízové smlouvy převedena pod provozování touto firmou od společnosti McDonald's spol. s.r.o. V prosinci roku 2014 byla otevřena druhá jihlavská pobočka v nově postaveném nákupním centru City Park. Tato pobočka nabízí jen omezený základní sortiment produktů. Jedná se o koncept satelitních restaurací, které se nasazují právě v obchodních centrech. V témže měsíci, jen pár dní před Vánoci, se také otevřela zbrusu nová restaurace u vjezdu do Avion Shopping Parku v Brně. Jedná se o samostatnou restauraci, která nabízí možnost nákupu přes McDrive, je tu také kavárna McCafé a krásný dětský koutek. Momentálně firma nemá více stálých poboček

McDonald's. Dříve bylo možné potkat na mezinárodní přehlídce ohňostrojů Ignis Brunensis mobilní stánek McDonald’s, který prodával pouze pár základních sendvičů z nabídky, avšak od roku 2015 se tento stánek již neprovozuje.

2.1.1 Rohlenka

Tato provozovna se nachází na známém odpočívadle Rohlenka, které je na 207,5km dálnice D1 za Brnem směrem na Olomouc. Denní tržby se pohybují mezi 100 a 300 tisíci. Nabízí možnost prodeje přímo do auta McDrive, a tvoří okolo 30 až 35% tržeb. Tato restaurace má také kavárenský koncept McCafé, kde se na samostatném baru dají zakoupit nejrůznější druhy kávy a deserty. Tržby z McCafé tvoří přibližně 10% z tržeb restaurace. Tržby jsou zde největší o víkendu, popř. v období svátků, v celoročním hodnocení to je o prázdninách. Tržby ovlivňuje především provoz na dálnici, ale také počasí. V roce 2015, kdy se opravovala dálnice, a byl uzavřen sjezd z D1 na odpočívku, tak tržby klesly až o 55%. Také pokud se stane nehoda a na dálnici v okolí odpočívky se tvoří kolony, tak jsou hodinové tržby menší. Tuto provozovnu také velice často navštěvují zahraniční zákazníci, především z Polska, a na jejich tržbách se především v období letních prázdnin podílí nemalou částkou. Odpočívadlo Rohlenka také využívá spousta řidičů autobusu k přestávce, kdy potom cestující autobusu se jdou najíst do restaurací. Řidiči mají domluvené jídlo zadarmo, pokud do McDonald's přivedou zákazníky, což také zvyšuje motivaci řidičů zde zastavovat. Tato provozovna má konkurenci přímo na odpočívadle, a to v podobě KFC, Subway a samotného motorestu Rohlenka, avšak počtem zákazníků i tržbami je zde McDonald's, dle konzultací s manažery ostatních provozoven, na lepší úrovni.

Tato diplomová práce se bude zabývat právě statistickou analýzou vlivu teploty a spotřebu určitých surovin na této restauraci.

2.2 Seznámení s problematikou objednávek chlazeného zboží

2.2.1 Systém objednávek

Do McDonald’s v ČR dodává veškeré suroviny HAVI Logistics s. r. o. Jedná se o výhradního dodavatele na náš trh a je zakázáno používat suroviny z jiného zdroje. Samotné zajištění dodavatelů surovin domlouvá obchodní oddělení McDonald’s, které mimo jiné kontroluje kvalitu a bezpečnost potravin, schopnost dodání dostatečného množství a také domlouvá cenu. HAVI už poté komunikuje s dodavatelem a na základě poptávky od restaurací objednává zboží na svůj sklad a poté pomocí mrazících/chladících kamionů rozváží do restaurací.

Zboží se dělí dle tepelného režimu na suché, mrazené a chlazené. Suché zboží může být v teplotách do 30°C, chlazené do 4°C a mrazené do -18°C. Kamiony mají rozdělenou mrazící a chlazenou zónu a tak je při dopravě vždy zajištěn odpovídající teplotní režim.

Každá restaurace má svůj harmonogram dodávek, na Rohlence je to středa a sobota.

V IS restaurací jsou suroviny rozděleny do následujících kategorií:

Číslo kategorie	Suroviny	Dodávka zboží
1	Velká objednávka	středa, sobota
3	Mrazené zboží	středa, sobota
4	McCafé	středa, sobota
5	Ostatní zboží	středa, sobota
6	Chlazené I.	středa, sobota
7	Chlazené II.	středa, sobota
9	OPS	středa

Tabulka 1: Kategorie zboží
(Zdroj: IS McD Rohlenka, zpracování vlastní)

Kategorie 1 – v této kategorií je nejvíce surovin. Jedná se jak o suché zboží, tak chlazené. Patří sem například sýr, omáčky, polevy, ale také veškerý obalový materiál.

Kategorie 3 – zde jsou všechny suroviny, které podléhají mrazenému teplotnímu režimu.

Kategorie 4 – patří sem veškeré suroviny, které se používají na McCafé. Obsahuje suroviny ze všech tří teplotních režimů, tedy jak zmrazené deserty, tak mléko, ale i kelímky a sirupy.

Kategorie 5 – do této kategorie se dávají suroviny, které se již neobjednávají, ale jsou stále aktivní v systému. Dávají se sem také suroviny, které se objednávají jen minimálně, proto se i z této kategorie občas nějaké suroviny objednají.

Kategorie 6 – obsahuje zboží, které je v chlazeném teplotním režimu a má krátkou dobu spotřeby – mléko, cibule, ovocný kelímek.

Kategorie 7 – obsahuje zboží, které je v chlazeném teplotním režimu a má krátkou dobu spotřeby – saláty, rajčata.

Kategorie 9 – patří sem čisticí prostředky a další zboží, které HAVI distribuuje pouze jednou týdně. Toto zboží nemá takovou spotřebu, aby se muselo objednávat dvakrát týdně, a šetří se tak náklady na logistiku.

V tabulce níže je den, do kdy je nutné objednávku odeslat a den dodání dle jednotlivých kategorií.

Kategorie	Odeslání objednávky	Doručení zboží
1	úterý 7 hodin	středa 7 hodin
	čtvrtek 7 hodin	sobota 7 hodin
3	úterý 7 hodin	středa 7 hodin
	čtvrtek 7 hodin	sobota 7 hodin
4	úterý 7 hodin	středa 7 hodin
	čtvrtek 7 hodin	sobota 7 hodin
5	úterý 7 hodin	středa 7 hodin
	čtvrtek 7 hodin	sobota 7 hodin
6	neděle 7 hodin	středa 7 hodin
	středa 7 hodin	sobota 7 hodin
7	neděle 7 hodin	středa 7 hodin
	středa 7 hodin	sobota 7 hodin
9	úterý 7 hodin	středa 7 hodin

Tabulka 2: Termíny objednávek
(Zdroj: vlastní zpracování)

Objednané zboží se do restaurace zaváží ve středu a sobotu v 7 hodin ráno. Do roku 2011 si každá restaurace skládala zboží do svých skladů sama, ale poté se zavedl systém tzv. neviditelných dodávek, kde HAVI zajišťuje lidi na složení do skladů, a restaurace tak jen zkontroluje správnost složení a dostane fakturu s doručeným zbožím.

Odeslání objednávky je nutné zajistit do daného dne do 8 hodin ráno, kdy ji zákaznické oddělení HAVI zpracovává. Pokud restaurace zapomene objednávku vytvořit nebo ji jen odeslat, tak zákaznické oddělení kontaktuje restauraci s upozorněním a požadavkem co nejrychlejší nápravy. Za objednání surovin zodpovídá profit manažer, který standardně dělá objednávku den předtím, než se zpracovává zákaznickým oddělením HAVI. U většiny surovin HAVI drží nutné množství surovin na pokrytí spotřeby restaurací, avšak u chlazeného zboží s dobou spotřeby v rámci dnů se u dodavatele objednává přesný počet, tedy součet ze všech restaurací. Z tohoto důvodu se chlazené zboží objednává o den až dva dříve, než ostatní suroviny. Na tabulce níže je vidět rozpis termínu objednávek na restauraci.

Den objednání	Kategorie	Den dodání
Sobota	6	středa
	7	
Pondělí	1	
	3	
	4	
	9	
Úterý	6	sobota
	7	
Středa	1	
	3	
	4	

Tabulka 3: Termíny objednávek 2
(Zdroj: vlastní zpracování)

2.2.2 Automatický propočet objednávek

Informační systém McDonald‘s má v sobě funkci automatického propočtu množství objednání surovin. K propočtu spotřeby surovin do další dodávky používá následující vzorec:

$$spotřeba\ do\ další\ dodávky = s * n/\ 100000$$

, kde *s* je spotřeba suroviny za poslední týden na 100000Kč tržby a *n* je naplánovaná tržba do další dodávky.

Používá se zde spotřeba za poslední týden, aby se v propočtu zohlednila změna složení spotřeby co nejdříve.

Pro korektní fungování je třeba mít správně nastavené datum další dodávky a mít v informačním systému zadanou naplánovanou tržbu minimálně do další dodávky.

Po výpočtu spotřeby se odečte aktuální stav suroviny na skladu a případně množství, které je již objednané do dodávky ještě před tou, než na kterou se objednává. Nutné množství se zaokrouhlí nahoru na možnou objednatelnou jednotku (kus, bedna, paleta).

Tento výpočet pomáhá profit manažerovi v objednání surovin, konečné slovo má však on, protože systém nepočítá s žádnou rezervou.

2.2.3 Suroviny a trvanlivost

Tento výpočet funguje u většiny surovin velice dobře, vždy se nechává nějaké množství do rezervy, a i když se objedná o něco více, díky velkému obratu se surovina spotřebuje během týdně či dvou. Problém je však u chlazeného zboží z kategorie 6 a 7, protože toto zboží má velice krátkou dobu spotřeby a také je jejich spotřeba ovlivněna počasím. Tyto kategorie například obsahují mléko na výrobu zmrzlin a mléčných koktejlů, které se v teplém počasí více prodávají. V tabulce níže je přehled doby spotřeb od doručení.

Mléko má datum spotřeby 9 dní od doručení a zbytek chlazeného zboží jen 5 dnů. Tedy mléko ze středeční dodávky má spotřebu do čtvrtku dalšího týdne, avšak salát jen do neděle. Ještě lépe tuto situaci vystihují následující grafy.

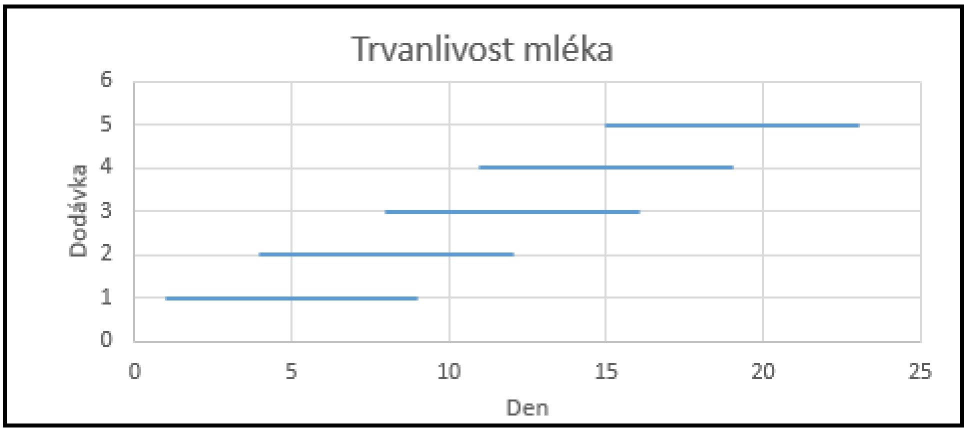

Obrázek 3: Trvanlivost mléka
(Zdroj: vlastní zpracování)

U mléka je překryv v trvanlivosti mléka z jednotlivých dodávek 5 až 6 dní, v závislosti na termínu dodávky. Zároveň datum spotřeby z první dodávky zasahuje trvanlivostí až do třetí dodávky. U této suroviny je tedy rezerva až 6 dnů, což proces objednávání usnadňuje a profit manažer se nemusí bát objednat větší množství mléka do rezervy, aniž by mu skončila trvanlivost a muselo se zlikvidovat.

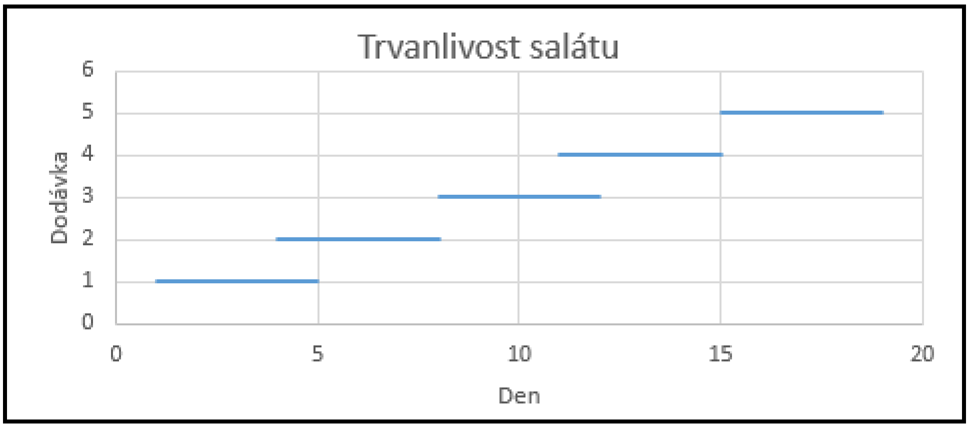

Obrázek 4: Trvanlivost salátů
(Zdroj: vlastní zpracování)

U ostatních položek, tedy salátu a rajčat je překryv v trvanlivost jen 1 až 2 dny, opět v závislosti na termínu dodávky. Tato situace dává profit manažerovi při objednávání malý manévrovací prostor a je tak nutné objednat zboží co nejpřesněji, aby se zbytečně nelikvidovaly suroviny s prošlou dobou spotřeby. Také může nastat opačná situace, kdy nebude suroviny dostatek do další dodávky a potom jsou jen tři možnosti, jak situaci vyřešit.

S distribučním centrem HAVI je možné domluvit mimořádnou dodávku, která restauraci výjimečně zaveze přiobjednaným zbožím. Je však nutné si nedostatek suroviny uvědomit včas, protože dodavatel nejdříve musí dodatečné množství suroviny vyrobit. Následuje distribuce do centrálního skladu HAVI a odtud do restaurace. Je tak nutné do tohoto problému zainteresovat mnoho lidí. Jedná se o zákaznické centrum, se kterým komunikuje restaurace, dále šéf logistiky, který musí zajistit volný kamion a také řidiče tohoto kamionu a nakonec také pracovníky na straně distributora, kteří tuto mimořádnou dodávku musí připravit. Z těchto důvodů je poplatek za mimořádnou dodávku 5000Kč a tato možnost se tak využívá až v krajní situaci, kdy není jiného řešení. Dodání suroviny je standardně druhý pracovní den.

Druhou možností je také domluvit se se zákaznickým centrem HAVI na mimořádné dodávce. Avšak v určitých případech není třeba vypravovat speciální kamion, ale přiložit zboží do jiného kamionu, který má naplánovanou cestu okolo restaurace. Při této možnost není třeba zásadněji upravovat plán jízdy a povolávat řidiče kamionu navíc. Pokud není žádná trasa kamionu blízko restaurace, je možné si domluvit vykládku na jiné restauraci s tím, že si objednávající restaurace sama zajistí odvoz. Pro HAVI vzniká jen zdržení v rámci desítek minut. Poplatek se domlouvá individuálně a jedná se o stovky korun.

Poslední možností je půjčit si surovinu z jiné restaurace, kde ji mají dostatek. Přesun suroviny si zajišťuje restaurace sama. Jedná se o první řešení, o které se restaurace snaží, protože náklady této možnosti jsou pouze za projetý benzín a čas manažera strávený s řešením situace a s přesunem.

Každopádně jak řešení chybějící suroviny, tak likvidace přebytku surovin přináší restauraci náklady navíc. Moje hypotéza je, že spotřeba chlazených surovin z kategorie 6 a 7 je ovlivněna počasím. Cílem této diplomové práce je potvrdit tuto hypotézu a vytvořit algoritmus pro profit manažera, který na základě dostupných dat z prodejů v minulosti a počasí pomocí statistických metod vypočítá množství suroviny, které je potřeba objednat.

2.3 Popis vstupních dat

V diplomové práci budu řešit spotřebu následujících surovin. Wrin je zkratka z anglického slova worldwide raw item number (13) a jedná se o jedinečné identifikační číslo suroviny. Toto označení se používá z důvodů velkého množství surovin od velkého množství dodavatelů.

Název: Sundae mléko

Wrin: 12/480

Výrobce: Farma Majcichov a.s.

Objednatelná jednotka: 1 bedna - 15 litrů

Trvanlivost: 9 dní

Použití: Používá se k výrobě zmrzlin a předpokládám, že spotřebu ovlivňuje počasí.

Obrázek 5: Sundae mléko
(Zdroj: vlastní foto)

Název: Shake mléko

Wrin: 11/354

Výrobce: Farma Majcichov a.s.

Objednatelná jednotka: 1 bedna - 15 litrů

Trvanlivost: 9 dní

Použití: Používá se k výrobě mléčných koktejlů (shaků) a očekávám vliv počasí na spotřebu

Obrázek 6: Shake mléko
(Zdroj: vlastní foto)

Název: Ledový salát

Wrin: 18/354

Výrobce: Eisberg sp. z o.o.

Objednatelná jednotka: 1 sáček – 1kg

Trvanlivost: 5 dnů

Použití: Používá se jako salát do různých sendvičů a nepředpokládám vliv počasí na spotřebu.

Obrázek 7: Ledový salát
(Zdroj: vlastní foto)

Název: Salátová směs

Wrin: 134/594

Výrobce:

Objednatelná jednotka: 1 sáček – 0,7kg

Trvanlivost: 5 dnů

Použití: Používá se jako salátový základ do zahradního a caesar salátu, předpokládám vliv počasí na spotřebu.

Obrázek 8: Salátová směs
(Zdroj: vlastní foto)

Název: Rajčata

Wrin: 9518/0

Výrobce: Slovatys s.r.o.

Objednatelná jednotka: 1 sáček – 2kg

Trvanlivost: 5 dnů

Použití: Používá se do malého množství sendvičů a nepředpokládám vliv počasí na spotřebu.

Obrázek 9: Rajčata
(Zdroj: vlastní foto)

Zdroj spotřeby dané suroviny v daný den je v manažerském IS MyStore v přehledu denních karet. Zde lze zobrazit informace o surovině za daný měsíc. Pro účely této diplomové práce je potřeba sloupec teoretická spotřeba, což je teoretická spotřeba na základě všech prodaných sendvičů v daném dni. Od reálné spotřeby se může lišit a to z důvodu špatně spočítané inventury na konci dne nebo špatným dávkováním surovin do sendvičů. Reálná odchylka mezi teoretickou a reálnou spotřebou je v rámci jednotek, proto budu do výpočtů počítat teoretickou spotřebu a případnou diferenci zohledním až při výpočtu množství zboží v objenávce.

Rest...: 16 Denní Karta Suroviny Datum: 22.02.16
DSPMKTO [3.70] 12/480 SUNDAE MIX 15 L (LIT) Čas : 04:42:27

Den 2016	Počát. Stav	Dodáv. +/-	Transf +/-	Odpad Promo	Teor. spot.	Teor. Sklad	Inv.	Skut. výtěž.	Rozd. množ.	Rozd. částka
01.01	33				18	15	18	10,4	3	90,27
02.01	18	120			20	118	115	7,2	-3	-97,82
03.01	115				16	99	101	9,6	2	50,63
04.01	101				4	97	98	10,5	1	23,20
05.01	98				8	90	87	6,3	-3	-76,50
06.01	87	60			11	136	139	11,8	3	87,02
07.01	139				12	127	124	6,8	-3	-88,35
08.01	124				25	98	102	9,7	3	86,64
09.01	102	30			38	93	95	8,9	2	46,02
10.01	95				35	60	60	8,5	0	4,58
11.01	60				18	42	45	9,9	3	70,37
12.01	45				19	26	26	8,5	0	-2,82
13.01	26	45			19	52	49	7,4	-3	-74,54
14.01	49		8		24	33	32	8,3	-1	-16,63
15.01	32				41	-9	10	16,0	9	544,50
16.01	10	150			48	112	116	9,2	4	102,60

Obrázek 10: Denní karty
(Zdroj: IS McD Rohlenka, vlastní foto)

Dále budu potřebovat přehled denních tržeb. Ten zjistím z modulu „sales history“, který zobrazuje různé informace od denní tržby a počtu zákazníků až po rozdíl oproti stejnému dni v minulém roce. Z důvodu utajení tržeb zde není obrázek tohoto modulu.

Jako zdroj dat pro teploty jsem využil archív teplot stránek in-pocasi.cz (14) pro Brno. Rozhodoval jsem se jakou teplotu do výpočtů použít, jestli maximální denní, průměrnou celodenní nebo průměrnou denní. Nakonec jsem se rozhodnul pro maximální denní už z toho důvodu, že pro další výpočty budu potřebovat předpověď počasí a ta je udávána v maximální denní teplotě. Průměrná celodenní bohužel nikde vypočítaná není a bylo by nutné použít zaznamenané teploty v průběhu dne a pomocí algoritmu je zprůměrovat tak, aby co nejreálněji odpovídali rozložení tržeb v rámci dne. Jelikož se však struktura tržeb v rámci dne mění v jak v týdnu, tak dle ročního období, bylo by velice těžké tento algoritmus vymyslet a upřesnění výpočtu touto metodou není jisté. Také by to bylo pro profit manažera až moc časově náročné. Průměrnou denní jsem nezvolil z důvodu zahrnutí také nočních teplot, přičemž noční tržby se na celkových podílejí maximálně 10%.

Teoretická spotřeba bude pro výpočty přepočítána na spotřebu na 100 tisíc Kč tržby, aby data měli stejnou váhu, a vypovídající hodnotu. Níže je vzorec pro přepočet této spotřeby.

$$spotřeba\ na\ 100\ tisíc\ Kč = \frac{spotřeba\ za\ daný\ den}{denní\ tržba} * 100000 \quad (2.1)$$

Kvalita dat z IS MyStore považuji za velice kvalitní a také archív teplot považuji za velice relevantní a kvalitní zdroj pro použití v této práci. Výpočty budu provádět na datech ze dne 1.7.2015 až 30.9.2015 a to z důvodu odstranění možných krátkodobých odchylek. Tabulka vstupních dat je v příloze 1.

Potřebná data pro výpočty také do programu Statistika. Níže je uvedený obrázek z programu s vloženými daty.

	1 Teplota	2 Shake	3 Sundae	4 Salát	5 Mix	6 Rajčata
1	28	15,84	26,22	7,65	3,82	6,01
2	29	15,55	30,07	7,78	3,11	5,70
3	31	19,21	31,61	7,60	3,60	5,60
4	33	16,82	33,63	6,86	3,43	5,15
5	35	17,48	37,51	6,92	4,01	5,46
6	34	23,45	28,79	6,99	4,11	5,76
7	35	26,27	35,43	7,33	5,50	6,11
8	29	9,97	30,44	8,40	3,15	6,30
9	25	10,08	22,08	7,68	3,36	5,76
10	22	11,50	26,06	8,05	3,07	6,51
11	25	13,24	26,49	7,33	2,82	5,35
12	31	18,57	33,25	7,19	3,00	5,69
13	24	14,95	20,25	7,71	2,89	5,79
14	27	12,23	20,75	7,98	2,66	6,38
15	27	15,11	24,08	8,97	2,83	7,55
16	31	15,99	31,98	7,99	3,55	7,11
17	35	17,89	26,06	8,95	4,28	6,61
18	35	16,95	28,16	8,05	3,74	6,03
19	35	17,06	31,01	7,75	3,10	5,27
20	30	15,07	24,95	8,32	3,12	6,76
21	34	17,76	34,04	7,40	3,95	6,41
22	36	16,01	32,53	8,51	3,50	7,01
23	30	14,49	25,71	8,41	2,80	7,01
24	34	14,57	28,78	8,01	3,64	6,92
25	31	15,84	29,64	8,18	3,07	6,13

Obrázek 11: Program Statistica s daty
(Zdroj: vlastní zpracování)

Mám zde celkem 6 sloupců proměnných. Pro zjednodušení označení v programu jsem použil pouze zkrácené názvy surovin. Salátem se rozumí ledový salát a mixem salátová směs. Tabulka má celkem 92 řádků hodnot.

Z vlastní zkušenosti vím, že spotřeba některých surovin je po přepočtu na 100 tisíc Kč tržby vyšší o víkendu a proto pro výpočty použiji jak pro data za celé tři měsíce, tak data rozdělená na všední dny a víkend. Do všedních dnů se počítají data za pondělí, úterý, středu a čtvrtek a do víkendu data z pátku, soboty a neděle. Poté porovnám, která z metod vykazuje vyšší korelaci. Připravím si tak ještě dvě tabulky. Vstupní data pro pracovní dny jsou v příloze 2, pro víkendy v příloze 3.

2.4 Test normality

Než se pustím do samotných výpočtů, je potřeba zjistit, zda jsou vstupní data normálního rozdělení a podle toho zvolím metodu výpočtu.

Pro výpočty a interpretaci dat využiji program Statistica.

Pro test normality volím Shipiro-Wilkův W test a pokud bude *p* hodnota větší než *1-zvolená hladina významnosti*, přijmu nulovou hypotézu H_0, tedy že data jsou normálního rozdělní. V opačném případě zamítám nulovou hypotézu H_0 a přijmu alternativní hypotézu H_1, tedy že data nejsou normálního rozdělení.

V programu Statistica je dostupný přes kartu Statistiky, položka Základní statistiky, modul Tabulky četností. Zde v kartě normalita zaškrtnu Shapiro-Wilkův W test a jako proměnné vyberu dané sloupce s daty. Po kliknutí na tlačítko Test normality se provede výpočet s následujícím výsledkem. Hladina významnosti je 95%.

	Testy normality (statstica)		
Proměnná	N	W	p
Teplota	92	0,943056	0,000548
Shake	92	0,963672	0,011533
Sundae	92	0,981346	0,211725
Salát	92	0,844703	0,000000
Mix	92	0,970642	0,035780
Rajčata	92	0,922489	0,000040

Obrázek 12: Test normality – všechna data
(Zdroj: vlastní zpracování)

Test ukázal, že data teplot a přepočtu spotřeby surovin na 100 tisíc Kč tržby u mléka shake, ledového salátu, salátové směny a rajčat nejsou normálního rozdělení, protože hodnota p je menší než 0,05 a zamítnul jsem nulovou hypotézu H_0 a přijal alternativní hypotézu H_1. Jen u dat z přepočtu u mléka sundae byla přijata nulová hypotéza H_0, tedy že tyto data jsou normálního rozdělení.

Nyní vypočítám normalitu také pro data rozdělená na všední dny a víkendy.

	Testy normality (data1)		
Proměnná	N	W	p
Teplota_p	52	0,956947	0,057736
Shake_p	52	0,923118	0,002450
Sundae_p	52	0,965157	0,130975
Salát_p	52	0,804828	0,000001
Mix_p	52	0,951171	0,032651
Rajčata_p	52	0,901616	0,000418

Obrázek 13: Test normality – data z pracovních dnů
(Zdroj: vlastní zpracování)

Test normality u všedních dnů ukázal, že data teplot a sundae mléka jsou normálního rozdělení. Ostatní data nemají normální rozdělení.

	Testy normality (data2)		
Proměnná	N	W	p
Teplota_v	40	0,917623	0,006488
Shake_v	40	0,973650	0,465872
Sundae_v	40	0,988923	0,958894
Salát_v	40	0,844597	0,000067
Mix_v	40	0,980246	0,698678
Rajčata_v	40	0,923710	0,010094

Obrázek 14: Test normality – víkendová data
(Zdroj: vlastní zpracování)

Test normality u pouze víkendových dat ukázal, že data u shake, sundae a mix jsou normálního rozdělení. Teplota, ledový salát a rajčata nejsou normálního rozdělení.

2.5 Korelace teploty a spotřeby surovin

Nyní se budu zabývat výpočtem korelace mezi maximální denní teplotou a spotřeby surovin na 100 tisíc Kč tržby.

Jelikož jsem pomocí Shapiro-Wilkovým testu normality zjistil, že některá data jsou normálního rozdělení a některá nejsou, budu používat pro výpočet korelace dvě metody – Pearsonův korelační koeficient a Kendallovo tau.

Pearsonův korelační koeficient použiji v případě, pokud jsou data normálního rozdělení aspoň u jednoho typu dat. Kendallovo tau použiji u všech případů, protože pouze u dat teploty a spotřeby sundae mléka v pracovních dnech jsou obě data normálního rozdělení. V případě použití obou metod provedu srovnání.

V programu Statistica se k výpočtu Kendallova tau dostanu přes kartu Statistika, možnost Neparametrické statistiky, modul Korelace (Spearman, Kendallovo tau, gama). Zde v seznamech proměnných vyberu sloupec teploty a testované suroviny.

Ve volbě Vytvořit vyberu v rolovací roletě Detailní report a v kartě Další výsledky vyberu Kendallovo tau.

Pro výpočet Pearsonova korelačního koeficientu použiji možnost Základní statistiky v kartě Statistika. Dále modul Korelační matice. V možnostech vyberu Zobrazit r, p-hodnoty a N. Do seznamu 1 dám Teploty a do seznamu 2 testovanou surovinu.

2.5.1 Korelace u shake mléka

U dat shake mléka budu počítat pouze Kendallovo tau u všech dat a u dat z pracovních dnů a víkendů také Pearsonův korelační koeficient a porovnám ho s Kendallovým tau.

Níže jsou výsledky výpočtu Kendallova tau u všech dat pomocí programu Statistica. Z je hodnota asysmptotické testové statistiky. Jedná se o vzorec, funkci dat, která udává, jak pravděpodobná jsou naměřená data, pokud platí nulová hypotéza. Tuto hodnotu nebudu potřebovat pro svoje výpočty.

	Kendallovy korelace tau (statstica) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	**Počet plat.**	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota & Shake	92	0,672405	9,493375	0,000000	----

Obrázek 15: Kendallovo Tau – teplota a shake mléko
(Zdroj: vlastní zpracování)

Korelační koeficient Kendallova tau u všech dat vyšel 0,67, což značí středně silnou přímou korelaci mezi teplotou a spotřebou shake mléka, tedy že čím je vyšší teplota, tím je spotřeba mléka větší. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Dále provedu výpočet Kendallova tau pouze u pracovních dnů.

Dvojice proměnných	Kendallovy korelace tau (data1) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000 Počet plat.	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_p & Shake_p	52	0,657562	6,880442	0,000000	----

Obrázek 16: Kendallovo Tau – teplota a shake mléko – pracovní dny
(Zdroj: vlastní zpracování)

Korelační koeficient Kendallova tau u dat z pracovních dnů vyšel 0,66, což značí středně silnou přímou korelaci mezi teplotou a spotřebou shake mléka v pracovních dnech, tedy čím je vyšší teplota, tím je spotřeba mléka větší. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Nyní provedu výpočet Pearsonova korelačního koeficientu na tyto data.

Proměnná	Korelace (data1) Označ. korelace jsou významné na hlad. p < ,05000 N=52 (Celé případy vynechány u ChD) Shake_p
Teplota_p	,7867
	p=,000

Obrázek 17: Pearsonův korelační koeficient – teplota a shake mléko – pracovní dny
(Zdroj: vlastní zpracování)

Pearsonův korelační koeficient u dat z pracovních dnů vyšel 0,79, což značí velice silnou přímou korelaci mezi teplotou a spotřebou shake mléka v pracovních dnech, tedy čím je vyšší teplota, tím je spotřeba mléka vyšší. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Při srovnání s Kendallovým tau vykazuje výpočet pomocí Pearsonova korelačního koeficientu vyšší korelaci.

Dále vypočítám Kendallovo tau pro data z víkendů.

Dvojice proměnných	Kendallovy korelace tau (data2) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000 Počet plat.	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_v & Shake_v	40	0,712836	6,478114	0,000000	----

Obrázek 18: Kendallovo Tau – teplota a shake mléko – víkend
(Zdroj: vlastní zpracování)

Kendallovo tau u dat z víkendu vyšlo 0,71, což značí velice silnou přímou korelaci mezi teplotou a spotřebou shake mléka o víkendech, tedy čím je vyšší teplota, tím je vyšší spotřeba tohoto mléka. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Nyní vypočítám Pearsonův korelační koeficient pro tato data.

Proměnná	Korelace (data2) Označ. korelace jsou významné na hlad. p < ,05000 N=40 (Celé případy vynechány u ChD) Shake_v
Teplota_v	,8742
	p=,000

Obrázek 19: Pearsonův korelační koeficient – teplota a shake mléko – víkend
(Zdroj: vlastní zpracování)

Pearsonův korelační koeficient u dat z víkendu vyšel 0,87, což značí velice silnou přímou koelaci mezi teplotou a spotřebou shake mléka o víkendech, tedy čím je vyšší teplota, tím je vyšší spotřeba tohoto mléka. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Při srovnání s Kendallovým tau vykazuje výpočet pomocí Pearsonova korelačního koeficientu vyšší korelaci.

Zjistil jsem, že teplota ovlivňuje spotřebu shake mléka a to více o víkendu, než v pracovní dny.

2.5.2 Korelace u sundae mléka

U dat sundae mléka budu počítat u všech dat Kendallovou tau i Personův korelační koeficient a porovnám ho s Kendallovým tau.

Níže je výpočet Kendallova tau u všech dat pomocí programu Statistica.

	Kendallovy korelace tau (statstica) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	Počet plat.	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota & Sundae	92	0,546145	7,710776	0,000000	----

Obrázek 20: Kendallovo Tau – teplota a sundae mléko
(Zdroj: vlastní zpracování)

Kendallovo tau u všech dat vyšlo 0,55, což značí středně silnou přímou korelaci mezi teplotou a spotřebou sundae mléka, tedy že čím je vyšší teplota, tím je tato spotřeba větší. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Dále vypočítám Pearsonův korelační koeficient pro tato data.

Proměnná	Korelace (statstica) Označ. korelace jsou významné na hlad. p < ,05000 N=92 (Celé případy vynechány u ChD) Sundae
Teplota	,7407
	p=,000

Obrázek 21: Pearsonův korelační koeficient – teplota a sundae mléko
(Zdroj: vlastní zpracování)

Pearsonův korelační koeficient pro všechna data vyšel 0,74, což značí velmi silnou přímou korelaci mezi teplotou a spotřebou sundae mléka, tedy čím je vyšší teplota, tím je spotřeba tohoto mléka větší. Jelikož je hodnota *p* menší než 0,05, je statisticky korelace významná.

Při porovnání s Kendallovým tau vykazuje výpočet pomocí Pearsonova korelačního koeficientu vyšší korelaci.

Dále provedu výpočet Kendallova tau pro data pracovních dnů.

Dvojice proměnných	Kendallovy korelace tau (data1) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000 Počet plat.	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_p & Sundae_p	52	0,675998	7,073352	0,000000	----

Obrázek 22: Kendallovo Tau – teplota a sundae mléko – pracovní dny
(Zdroj: vlastní zpracování)

Kendallovo tau pro pracovní dny vyšlo 0,68, což značí středně silnou korelaci mezi teplotou a spotřebou sundae mléka v pracovních dnech, tedy čím je teplota vyšší, tím je vyšší spotřeba tohoto mléka. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Nyní provedu výpočet Pearsonova korelačního koeficientu pro tyto data.

Proměnná	Korelace (data1) Označ. korelace jsou významné na hlad. p < ,05000 N=52 (Celé případy vynechány u ChD) Sundae_p
Teplota_p	,8523
	p=,000

Obrázek 23: Pearsonův korelační koeficient – teplota a sundae mléko – pracovní dny
(Zdroj: vlastní zpracování)

Pearsonův korelační koeficient pro pracovní dny vyšel 0,85, což značí velice silnou korelaci mezi teplotou a spotřebou sundae mléka v pracovních dnech, tedy čím je vyšší teplota, tím je vyšší spotřeba tohoto mléka. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Při porovnání s Kendallovým tau vykazuje výpočet pomocí Pearsonova korelačního koeficientu vyšší korelaci.

Nyní provedu výpočet Kendallova tau pro data z víkendů.

Dvojice proměnných	Kendallovy korelace tau (data2) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000 Počet plat.	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_v & Sundae_v	40	0,464203	4,218586	0,000025	----

Obrázek 24: Kendallovo Tau – teplota a sundae mléko – víkend
(Zdroj: vlastní zpracování)

Kendallovo tau u výpočtů víkendová data vyšlo 0,46, což značí středně silnou korelaci mezi teplotou a spotřebou sundae mléka o víkendu, tedy čím je vyšší teplota, tím je vyšší spotřeba mléka. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Nyní provedu výpočet Pearsonova korelačního koeficientu pro tato data.

Proměnná	Korelace (data2) Označ. korelace jsou významné na hlad. p < ,05000 N=40 (Celé případy vynechány u ChD) Sundae_v
Teplota_v	,6428
	p=,000

Obrázek 25: Pearsonův korelační koeficient – teplota a sundae mléko – víkend
(Zdroj: vlastní zpracování)

Pearsonův korelační koeficient pro víkendová vyšel 0,64, což značí středně silnou přímou korelaci mezi teplotou a spotřebou sundae mléka o víkendu, tedy čím je teplota vyšší, tím je vyšší spotřeba tohoto mléka. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Při porovnání s Kendallovým tau vykazuje výpočet pomocí Pearsonova korelačního koeficientu vyšší korelaci.

Zjistil jsem, že teplota ovlivňuje spotřebu sundae mléka a to více v pracovní dny, než o víkendu.

2.5.3 Korelace u ledového salátu

U dat ledového salátu budu počítat Kendallovo tau u všech dat a Pearsonův korelační koeficient u dat z pracovních dnů a porovnám ho s Kendallovým tau.

Níže je výpočet Kendallova tau pro všechna data.

	Kendallovy korelace tau (statstica) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	**Počet plat.**	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota & Salát	92	-0,413524	-5,83836	0,000000	----

Obrázek 26: Kendallovo Tau – teplota a ledový salát
(Zdroj: vlastní zpracování)

Korelační koeficient Kendallova tau vyšel -0,41, což značí středně silnou nepřímou korelaci mezi teplotou a spotřebou salátu, tedy čím je vyšší teplota, tím je menší spotřeba salátu. Jelikož je hodnota *p* menší, než 0,05, je tato korelace statisticky významná.

Níže je výpočet Kendallova tau u dat z pracovních dnů.

	Kendallovy korelace tau (data1) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	**Počet plat.**	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_p & Salát_p	52	-0,365654	-3,82604	0,000130	----

Obrázek 27: Kendallovo Tau – teplota a ledový salát – pracovní dny
(Zdroj: vlastní zpracování)

Kendallovo tau u dat z pracovních dnů vyšel -0,37, což značí středně malou nepřímou korelaci mezi teplotou a spotřebou salátu v pracovních dnech, tedy čím je vyšší teplota, tím je menší spotřeba salátu. Jelikož je *p* hodnota menší, než 0,05, je tato korelace statisticky významná.

Nyní vypočítám Pearsonův korelační koeficient pro tyto data.

Proměnná	Korelace (data1) Označ. korelace jsou významné na hlad. p < ,05000 N=52 (Celé případy vynechány u ChD) Salát_p
Teplota_p	-,4800
	p=,000

Obrázek 28: Pearsonův korelační koeficient – teplota a ledový salát – pracovní dny
(Zdroj: vlastní zpracování)

Pearsonův korelační koeficient u dat z pracovních dnů vyšel -0,48, což značí středně silnou nepřímou korelaci mezi teplotou a spotřebou salátu v pracovních dnech, tedy čím je teplota vyšší, tím je menší spotřeba salátu. Jelikož je *p* hodnota menší, než 0,05, je tato korelace statisticky významná.

Při porovnání s Kendallovým tau vykazuje výpočet pomocí Pearsonova korelačního koeficientu vyšší korelaci.

Nyní provedu výpočet Kendallova tau pro data z víkendů.

	Kendallovy korelace tau (data2) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	Počet plat.	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_v & Salát_v	40	-0,488008	-4,43492	0,000009	----

Obrázek 29: Kendallovo Tau – teplota a ledový salát – víkend
(Zdroj: vlastní zpracování)

Kendallovo tau u dat v víkendů vyšel -0,49, což značí středně silnou nepřímou korelaci mezi teplotou a spotřebou salátu o víkendech, tedy čím je teplota vyšší, tím je menší spotřeba salátu. Jelikož je hodnota *p* menší, než 0,05, je korelace statisticky významná.

Zjistil jsem, že teplota nepřímo ovlivňuje spotřebu salátu a to více o víkendu, než v pracovních dnech.

U této suroviny jsem očekával nízkou korelaci. Středně silná nepřímá korelace jde zdůvodnit tak, že v horkém počasí lidé méně kupují jídlo se salátem a také, že podíl studených desertů na celkových tržbách je vyšší a tím tak sráží spotřebu na 100 tisíc tržeb dolů.

2.5.4 Korelace u salátové směsi

U dat salátové směsi budu počítat Kendallovo tau ve všech případech a u dat z pracovních dnů také Pearsonův korelační koeficient a porovnám ho s Kendallovým tau.

Níže je výpočet Kendallova tau pro všechny data.

	Kendallovy korelace tau (statstica) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	**Počet plat.**	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota & Mix		0,370948	5,237248	0,000000	----

Obrázek 30: Knedallovo Tau – teplota a salátová směs
(Zdroj: vlastní zpracování)

Kendallovo tau vyšlo 0,37, což značí středně malou přímou korelaci mezi teplotou a spotřebou salátové směsi, tedy čím je větší teplota, tím je větší spotřeba tohoto salátu. Jelikož je hodnota *p* menší, než 0,05, je tato korelace statisticky významná.

Níže je výpočet Kendallova tau u dat z pracovních dnů.

	Kendallovy korelace tau (data1) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	**Počet plat.**	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_p & Mix_p	52	0,304199	3,183008	0,001458	----

Obrázek 31: Kendallovo Tau – teplota a salátová směs – pracovní dny
(Zdroj: vlastní zpracování)

Kendallovo tau u dat z pracovních dnů vyšlo 0,30, což značí středně malou přímou korelaci mezi teplotou a spotřebou salátové směsi v pracovní dny, tedy čím je vyšší teplota, tím je spotřeba tohoto salátu větší. Jelikož je hodnota *p* menší, než 0,05, je tato korelace statisticky významná.

Níže je výpočet Pearsnova korelačního koeficientu pro tyto data.

	Korelace (data1) Označ. korelace jsou významné na hlad. p < ,05000 N=52 (Celé případy vynechány u ChD)
Proměnná	**Mix_p**
Teplota_p	,4560
	p=,001

Obrázek 32: Pearsonův korelační koeficient – teplota a salátová směs – pracovní dny
(Zdroj: vlastní zpracování)

Pearsonův korelační koeficient pro data z pracovních dnů vyšel 0,46, což značí středně silnou přímou korelaci, tedy čím je vyšší teplota, tím je vyšší spotřeba salátové směsi v pracovní dny. Jelikož je hodnota *p* menší, než 0,05, je tato korelace statisticky významná.

Při porovnání s Kendallovým tau vykazuje výpočet pomocí Pearsonova korelačního koeficientu vyšší korelaci.

Níže je výpočet Kendallova tau o víkendu.

	Kendallovy korelace tau (data2) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	**Počet plat.**	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_v & Mix_v	40	0,490653	4,458961	0,000008	----

Obrázek 33: Kendallovo Tau – teplota a salátová směs – víkend
(Zdroj: vlastní zpracování)

Kendallovo tau u dat z víkendu vyšel 0,49, což značí středně silnou přímou korelaci mezi teplotou a salátovou směsí o víkendu, tedy čím je vyšší teplota, tím je vyšší spotřeba tohoto salátu. Jelikož je hodnota *p* menší, než 0,05, je tato korelace statisticky významná. Zjistil jsem, že teplota ovlivňuje spotřebu salátové směsi a to více o víkendu, než v pracovní dny.

2.5.5 Korelace u rajčat

U dat rajčat budu počítat Kendallovo tau ve všech případech u dat u dat z pracovních dnů také také Pearsonnův korelační koeficient a porovnám ho s Kendallovým tau.

Níže je výpočet Kendallova tau pro všechna data.

	Kendallovy korelace tau (statstica) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
Dvojice proměnných	**Počet plat.**	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota & Rajčata	92	-0,038171	-0,538925	0,589938	----

Obrázek 34: Kendallovo Tau – teplota a rajčata
(Zdroj: vlastní zpracování)

Kendallovo tau vyšlo -0,04, což značí zanedbatelnou nepřímou korelaci mezi teplotou a spotřebou rajčat, tedy že teplota neovlivňuje spotřebu rajčat. Jelikož je hodnota *p* větší, než 0,05, není tato korelace statisticky významná.

Níže je výpočet Kendallova tau pro data z pracovních dnů.

Dvojice proměnných	Kendallovy korelace tau (data1) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
	Počet plat.	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_p & Rajčata_p	52	-0,058382	-0,610880	0,541279	----

Obrázek 35: Kendallovo Tau – teplota a rajčata – pracovní dny
(Zdroj: vlastní zpracování)

Kendallovo tau u dat z pracovních dnů vyšlo -0,06, což značí zanedbatelnou nepřímou korelaci mezi teplotou a spotřebou rajčat v pracovní dny, tedy že teplota neovlivňuje spotřebu rajčat. Jelikož je hodnota *p* větší, než 0,05, není tato korelace statisticky významná.

Nyní vypočtu Pearsonův korelační koeficient pro tato data.

Proměnná	Korelace (data1) Označ. korelace jsou významné na hlad. p < ,05000 N=52 (Celé případy vynechány u ChD)
	Rajčata_p
Teplota_p	-,2451
	p=,080

Obrázek 36: Pearsonův korelační koeficient – teplota a rajčata – pracovní dny
(Zdroj: vlastní zpracování)

Pearsonův korelační koeficient pro data z pracovních dnů vyšel -0,25, což značí slabou korelaci mezi teplotou a spotřebou rajčat v pracovní dny, tedy čím je vyšší teplota, tím je spotřeba rajčat menší. Jelikož je však hodnota *p* větší, než 0,05, není tato korelace statisticky významná.

Při porovnání s Kendallovým tau vykazuje výpočet pomocí Pearsonova korelačního koeficientu vyšší korelaci, avšak v obou případech tato korelace není statisticky významná.

Níže je výpočet Kendallova tau pro data z víkendů.

Dvojice proměnných	Kendallovy korelace tau (data2) ChD vynechány párově Označ. korelace jsou významné na hl. p <,05000				
	Počet plat.	Kendall tau	Z	p-hodn.	Přesné p 1stranné
Teplota_v & Rajčata_v	40	0,022483	0,204319	0,838104	----

Obrázek 37: Kendallovo Tau – teplota a rajčata – víkend
(Zdroj: vlastní zpracování)

Kendallovou tau pro data z víkendů vyšlo 0,02, což značí zanedbatelnou korelaci mezi teplotou a spotřebou rajčat o víkendu, tedy že teplota neovlivňuje spotřebu rajčat. Jelikož je hodnota *p* větší, než 0,05, není tato korelace statisticky významná.

Zjistil jsem, že teplota neovlivňuje spotřebu rajčat.

2.5.6 Shrnutí výsledku

U některých surovin jsem použil výpočet jak Kendallova tau, tak Pearsonova korelačního koeficientu. Pomocí dvou různých statistických metod na měření korelace jsem zjistil podobné výsledky a ověřil si tak jejich pravdivost.

Níže je přehled výpočtu Kendallova tau pro všechny data, pro data z pracovních dnů a pro data z víkendů.

Teplota/	Kendallovo tau		
	Všechna data	Pracovní dny	Víkendy
Shake	0,67	0,66	0,71
Sundae	0,55	0,68	0,46
Salát	-0,41	-0,37	-0,49
Salátová směs	0,37	0,30	0,49
Rajčata	-0,04	-0,06	0,02

Tabulka 4: Přehled korelací
(Zdroj: zpracování vlastní)

Rozdíl korelace mezi pracovními dny a víkendy je u shake mléka, salátu a rajčat velice malý, ale také u sundae mléka a salátové směsi nedosahuje větších rozdílů. Pro sjednocení metodiky budu nadále počítat pouze s výpočtem Kendallova tau pro všechna data.

U dat shake mléko, sundae mléko a salátová směs je středně silná přímá korelace, tedy čím je vyšší teplota, tím se zvyšuje spotřeba suroviny. U salátu byla zjištěna středně silná nepřímá korelace, tedy čím je teplota vyšší, tím je nižší spotřeba salátu a u rajčat nebyla zjištěna žádná statisticky významná korelace.

3 NÁVRH ŘEŠENÍ

Na základě analýzy dat se budu v této kapitole věnovat návrhu řešení problematiky objednávání chlazeného zboží. Cílem je vytvořit takový algoritmus, který na základě analýzy korelace mezi teplotou a spotřebou surovin, předpovědi počasí a naplánované tržbě vypočítá budoucí spotřebu surovin.

3.1 Naplánovaná tržba

Budoucí denní tržba se plánuje na jeden měsíc vždy týden před koncem předchozího měsíce. Počítá se z tržeb minulých let s přihlédnutím k aktuálnímu růstu, stagnaci či poklesu tržeb a na základě dalších poznatků, které mohou ovlivnit výši tržeb, například uzavírky na dálnici apod.

Tržba se tedy plánuje s procentuálním rozdílem tržeb oproti minulému roku. Plánuje ji profit manažer, případně vedoucí restaurace. Pokud se v průběhu měsíce zjistí odchylky od plánu, naplánovaná tržba se upravuje tak, aby co nejlépe odpovídala reálným tržbám.

Nyní provedu test statistické významnosti rozdílu mezi naplánovanou a reálnou tržbou v měsících červenec, srpen a září v roce 2014.

Pokud by byly data normálního rozdělení, použil bych Studentův t-test. Jedná se o parametrický test dvou středních hodnot.

Moje data však nejsou normálního rozdělení, proto musím použít neparametrický test, a to Wilcoxonův test. Tento test se v programu Statistica nachází v kartě Statistika, položka Neparametrické testy, modul Porovnání dvou závislých vzorků (proměnné). Vytvořil jsem novou tabulku se dvěma sloupci, kde v jednom byla naplánovaná tržba a v druhém reálná tržba za období červenec až září 2015.

Níže je výsledek výpočtu Wilcoxonova párového testu.

	Wilcoxonův párový test (Tabulka15) Označené testy jsou významné na hladině p <,05000			
Dvojice proměnných	Počet platných	T	Z	p-hodn.
trzba_plan & trzba_real	92	1846,000	1,140912	0,253908

Obrázek 38: Wicoxonův test – plánované a reálné tržby
(Zdroj: vlastní zpracování)

Jelikož je hodnota *p* větší, než 0,05, nemůžu zamítnout nulovou hypotézu, tedy rozdíl mezi naplánovanou a skutečnou tržbou není statisticky významný.

Naplánovanou tržbu na daný měsíc tedy v dalším výpočtech mohu použít bez statistického ovlivnění výsledku.

3.2 Předpověď počasí

Důležitou součástí algoritmu bude předpověď počasí, protože počasí ovlivňuje spotřebu některých surovin. Při výpočtu korelace jsem použil maximální denní teplotu a tu samou teplotu zobrazují předpovědi počasí. Stejně jako v případě naplánované tržby, i v tomto případě použiji Wilcoxonův párový test. Jako zdroj předpovědi počasí jsou jednou do týdne zapsané předpovědi počasí na období červenec až září 2015 z webu in-počasí.cz a jako zdroj dat pro reálné teploty použiji archív teplot z tohoto období ze stejného webu ze stanice Brno.

Data pro výpočty jsou uvedena v příloze číslo 4.

Opět jsem v programu statistika spustil Wilcoxonův párový test a níže je výsledek.

	Wilcoxonův párový test (Tabulka15) Označené testy jsou významné na hladině p <,05000			
Dvojice proměnných	**Počet platných**	T	Z	p-hodn.
teplota_pred & teplota_real	75	1368,500	0,298351	0,765435

Obrázek 39: Wilcoxonův test – předpovězená a reálná teplota
(Zdroj: vlastní zpracování)

Jelikož je hodnota p větší, než 0,05, nemůžu přijmout nulovou hypotézu, tedy rozdíl mezi předpovědí počasí a reálnou teplotou není statisticky významný.

Toto potvrzení je pro další výpočty velice důležité a v dalších výpočtech mohu použít předpověď počasí, protože její rozdíl od skutečné teploty daný den není statisticky významný.

3.3 Budoucí spotřeba surovin

3.3.1 Spotřeba na základě lineární regrese

Nyní je třeba vypočítat budoucí spotřebu surovin na 100000Kč tržby podle předpovědi počasí. K tomuto výpočtu využiji lineární regrese. Výsledkem této regrese je regresní přímka, má funkci (1.7):

$$y = b_1 + b_2 x$$

Přímka prochází mezi body tak, aby mezi nimi a přímkou byl co nejmenší rozdíl. Tuto metodu volím z důvodu rozlišných spotřeb v jednotlivých teplotách a proložení regresní přímkou se jeví jako nejlepší možnost.

Pro proložení regresní přímkou využiji program Statistica. V menu Grafy volím Bodový graf a v kartě detaily proložení Lineární. Jako osu x volím teplotu a jako osu y danou surovinu. Nejenže program zobrazí graf s proložením, ale také vypočítá hodnoty koeficientu b_1 a b_2 regresní přímky.

Takto vypočítám koeficienty u surovin shake mléko, sundae mléko, ledový salát a salátová směs. Pro rajčata také zobrazím graf s proložením regresní přímkou, avšak pro další výpočty nebudu používat koeficienty b_1 a b_2, ale průměrnou hodnotu spotřeby, protože Kendallovo Tau nepotvrdilo statisticky významnou korelaci mezi teplotou a spotřebou rajčat.

<u>Shake mléko</u>

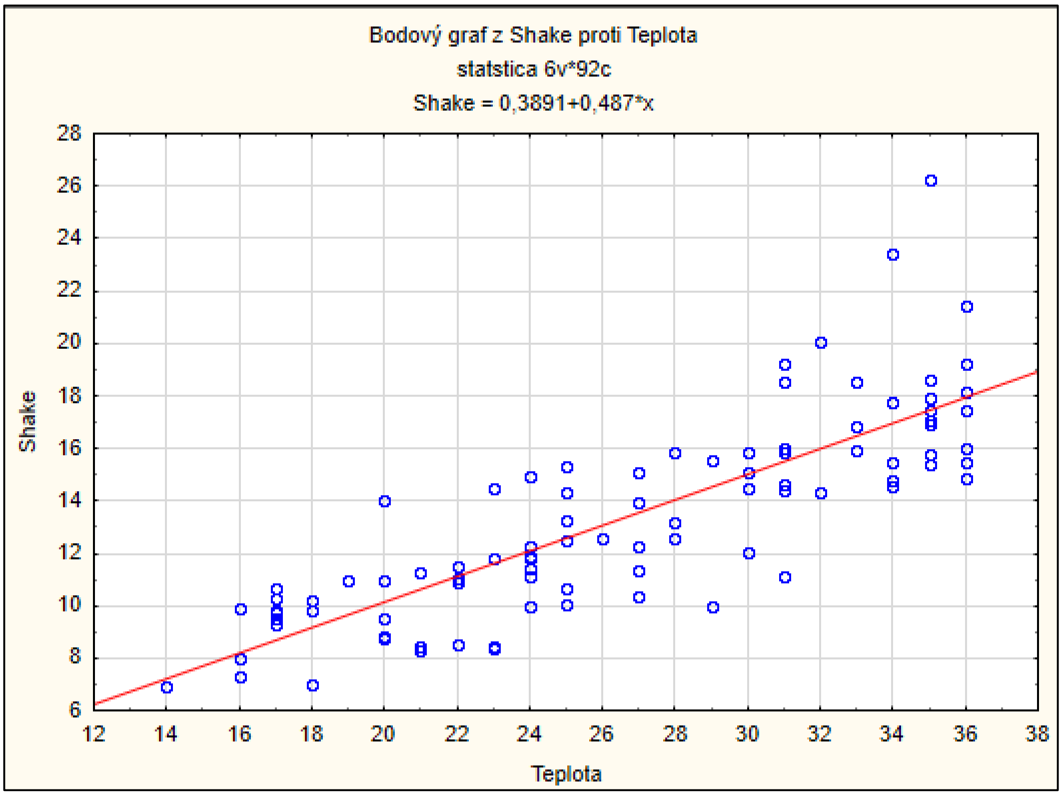

Obrázek 40: Graf teploty a spotřeby shake mléka
(Zdroj: vlastní zpracování)

$$y = 0{,}3891 + 0{,}487x$$

Hodnota koeficientu b_1 je 0,3891 a koeficientu b_2 je 0,487, tedy s každým stupněm teploty se zvyšuje spotřeba shake mléka na 100000Kč tržby o 0,487 litrů.

Sundae mléko

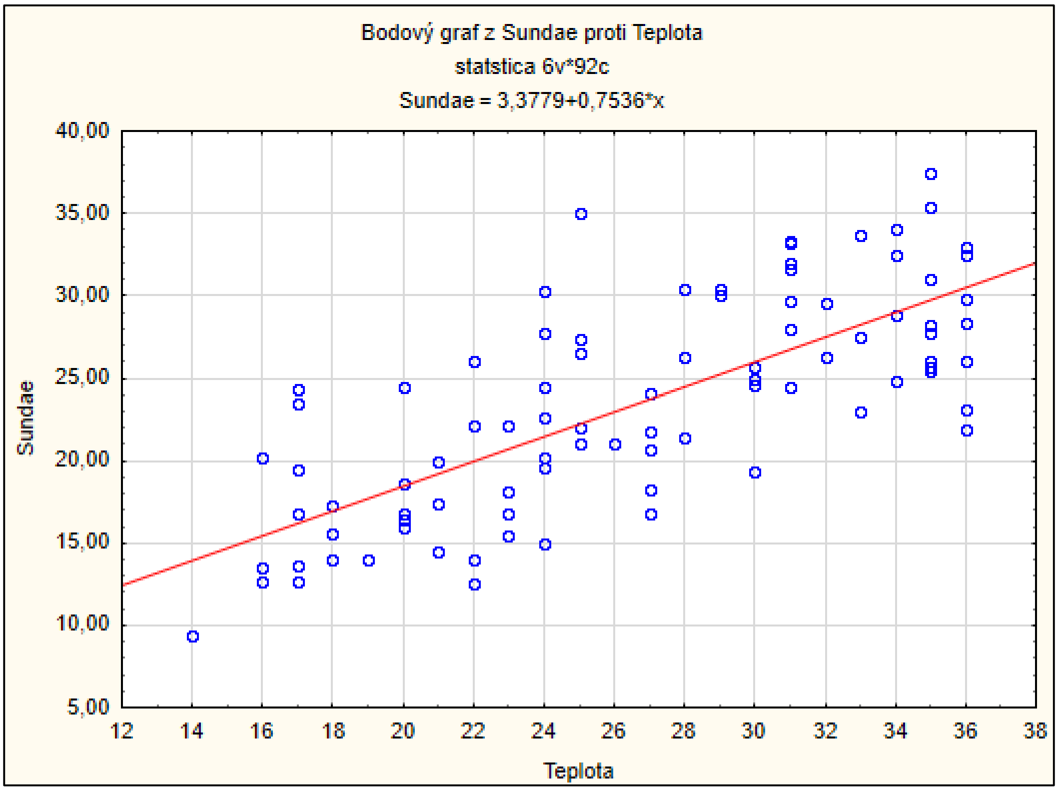

Obrázek 41: Graf teploty a spotřeby sundae mléka
(Zdroj: vlastní zpracování)

$$y = 3{,}3779 + 0{,}7536x$$

Hodnota koeficientu b_1 je 3,3779 a koeficientu b_2 je 0,7536, tedy s každým stupněm teploty se zvyšuje spotřeba sundae mléka na 100000Kč tržby o 0,7536 litrů. Je zde vidět silnější závislost spotřeby na teplotě než u shake mléka.

Ledový salát

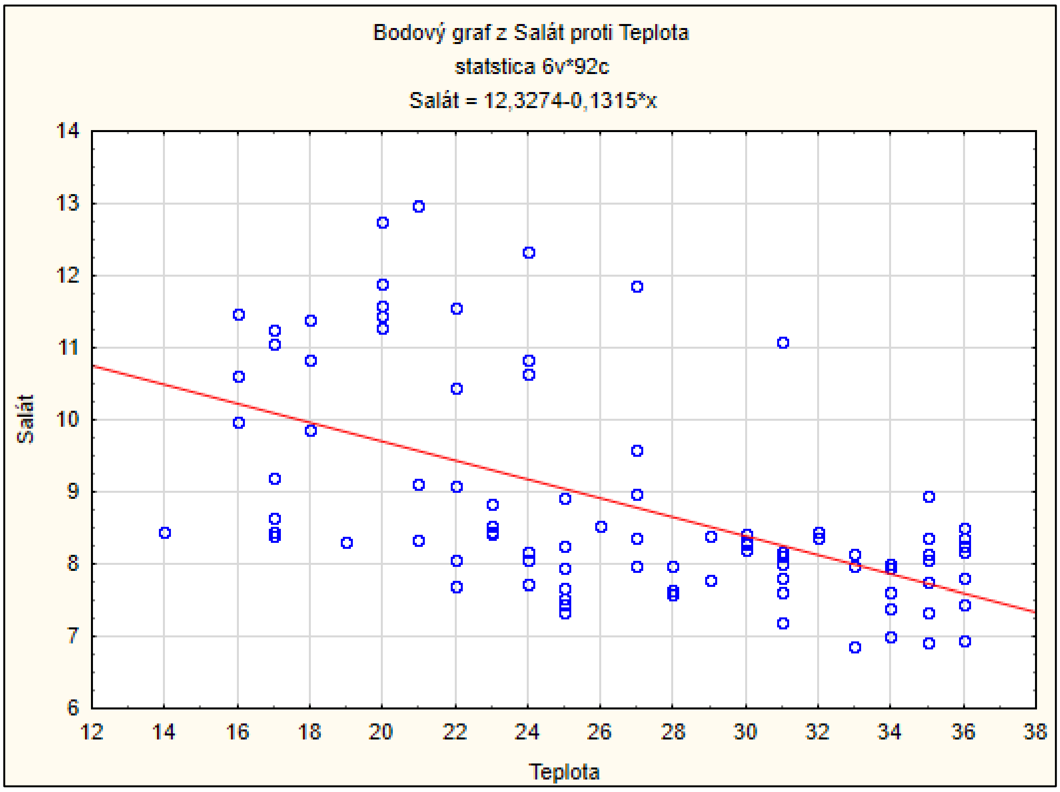

Obrázek 42: Graf teploty a spotřeby ledového salátu
(Zdroj: vlastní zpracování)

$$y = 12{,}3274 - 0{,}1315x$$

Hodnota koeficientu b_1 je 12,3274 a koeficientu b_2 je -0,1315, tedy s každým stupněm teploty se snižuje spotřeba ledového salátu na 100000Kč tržby o 0,1315 kilo. Potvrzuje tak nepřímá korelace mezi teplotou a spotřebou ledového salátu.

Salátová směs

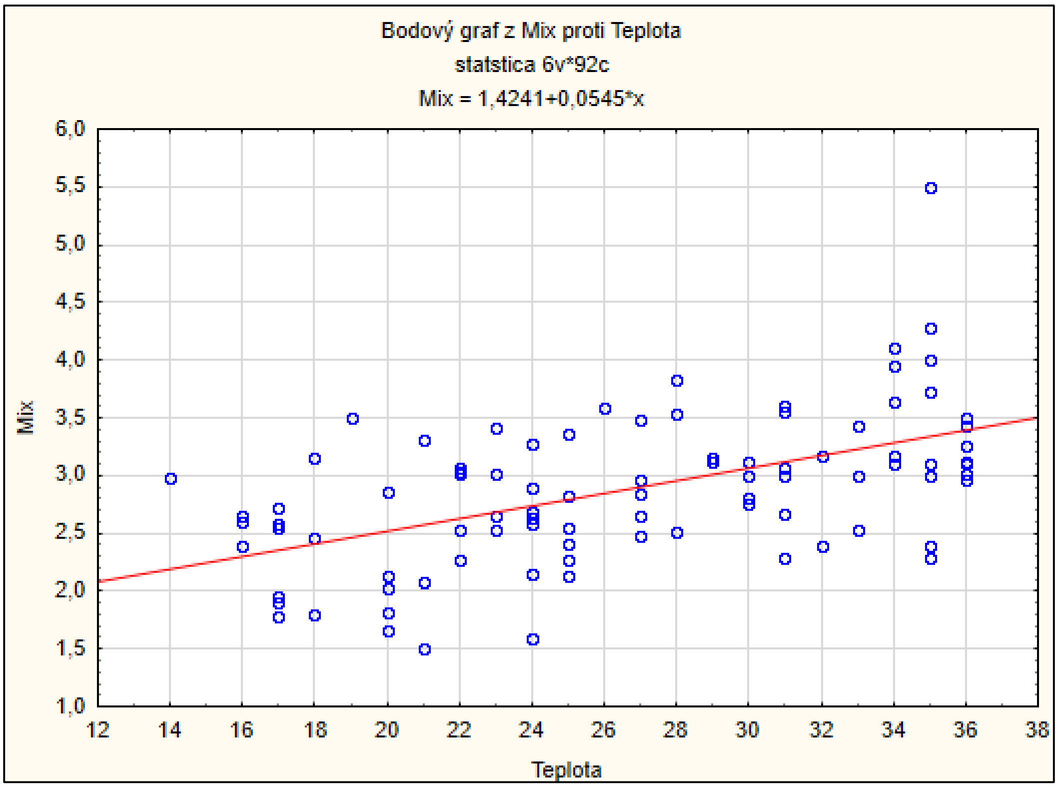

Obrázek 43: Graf teploty a spotřeby salátové směsi
(Zdroj: vlastní zpracování)

$$y = 1,4241 + 0,545x$$

Hodnota koeficientu b_1 je 1,4241 a koeficientu b_2 je 0,0545, tedy s každým stupněm teploty se zvyšuje spotřeba salátové směsi na 100000Kč tržby o 0,0545 kilo.

Rajčata

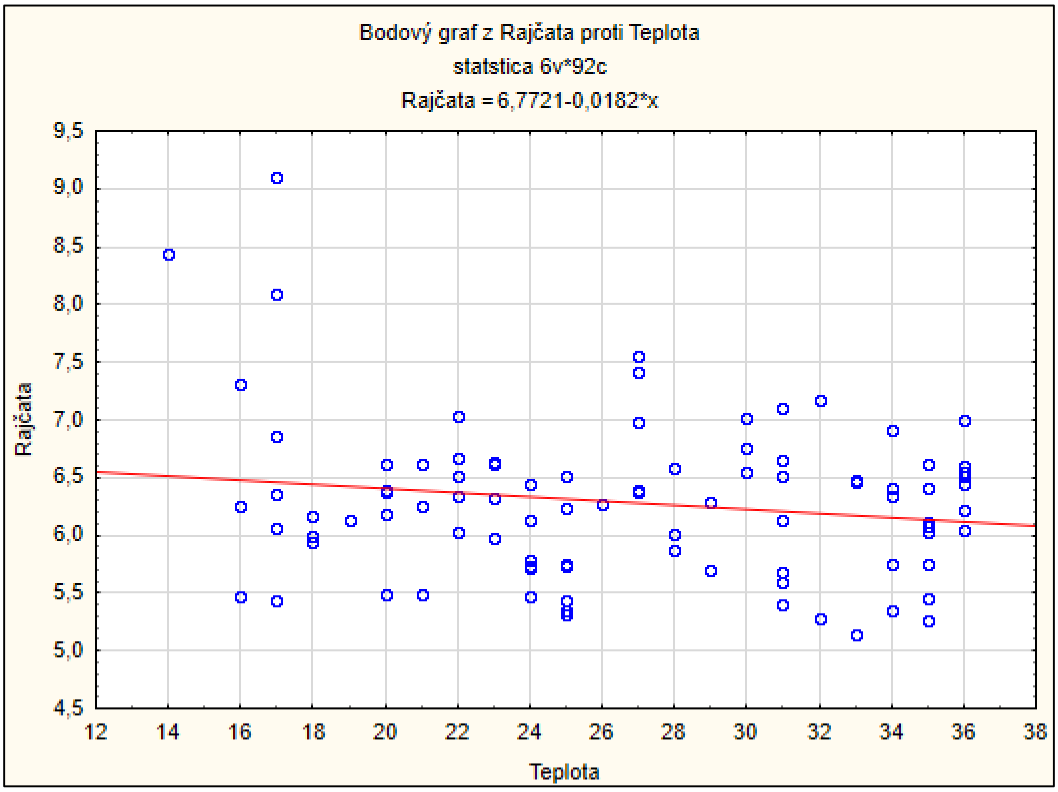

Obrázek 44: Graf teploty a s potřeby rajčat
(Zdroj: vlastní zpracování)

$$y = 6{,}7721 - 0{,}0182x$$

Hodnota koeficientu b_1 je 6,7721 a koeficientu b_2 je -0,0182, tedy s každým stupněm teploty se snižuje spotřeba rajčat na 100000Kč tržby o 0,0182 kilo. Kendallovo Tau však nepotvrdilo korelaci mezi teplotou a spotřebou rajčat a pro další výpočtu budu používat průměr hodnot.

Průměr hodnot zjistím v programu Statistika v kartě Statistika, možnost Základní statistiky, modul Popisné statistiky, kde vyberu proměnné Rajčata a dám Vypočítat.

Níže je uvedený výpočet pomocí tohoto modulu.

	Popisné statistiky (statstica)				
Proměnná	**N platných**	Průměr	Minimum	Maximum	Sm.odch.
Rajčata	92	6,287963	5,147581	9,097880	0,677735

Obrázek 45: Výpočet průměrné spotřeby rajčat
(Zdroj: vlastní zpracování)

Výsledný průměr pro spotřebu rajčat na 100000Kč tržby je 6,288kg, což použiji do dalších výpočtů.

Přehled výsledných hodnot

Níže v tabulce je přehled surovin a vypočítaných koeficientů.

Surovina	**Koeficient b_1**	**Koeficient b_2**
Shake mléko	0,3891	0,487
Sundae mléko	3,3779	0,7536
Ledový salát	12,3274	–0,1315
Salátová směs	1,4241	0,0545
Rajčata	6,288	0

Tabulka 5: Přehled koeficientů b_1 a b_2
(Zdroj: zpracování vlastní)

3.3.2 Výpočet budoucí spotřeby

Již mám provedené všechny analýzy a výpočty pro provedení výpočtu budoucí spotřeby jednotlivých surovin. Níže je vzorec pro výpočet budoucí spotřeby na základě naplánované tržby a počasí.

Shake mléko

$$y_{sh} = \sum_{i=1}^{m} \frac{t_i}{100000} * (0{,}3891 + 0{,}487 * x_i)$$

, kde
i je den a začíná číslem 1 pro aktuální den,
m je počet dní do příští dodávky surovin. Při objednávkách v sobotu na středeční dodávku je $m = 7$ a při objednávkách v úterý na sobotní dodávku je m = 8,

t_i je tržba v den i,
x_i je teplota v den i.

Sundae mléko

$$y_{su} = \sum_{i=1}^{m} \frac{t_i}{100000} * (3{,}3779 + 0{,}7536 * x_i)$$

, kde

i je den a začíná číslem 1 pro aktuální den,

m je počet dní do příští dodávky surovin. Při objednávkách v sobotu na středeční dodávku je $m = 7$ a při objednávkách v úterý na sobotní dodávku je $m = 8$,

t_i je tržba v den *i*,

x_i je teplota v den *i*.

Ledový salát

$$y_l = \sum_{i=1}^{m} \frac{t_i}{100000} * (12{,}3274 - 0{,}1315 * x_i)$$

, kde

i je den a začíná číslem 1 pro aktuální den,

m je počet dní do příští dodávky surovin. Při objednávkách v sobotu na středeční dodávku je $m = 7$ a při objednávkách v úterý na sobotní dodávku je $m = 8$,

t_i je tržba v den *i*,

x_i je teplota v den *i*.

Salátová směs

$$y_s = \sum_{i=1}^{m} \frac{t_i}{100000} * (1{,}4241 + 0{,}0545 * x_i)$$

, kde

i je den a začíná číslem 1 pro aktuální den,

m je počet dní do příští dodávky surovin. Při objednávkách v sobotu na středeční dodávku je $m = 7$ a při objednávkách v úterý na sobotní dodávku je $m = 8$,

t_i je tržba v den *i*,

x_i je teplota v den *i*.

Rajčata

$$y_r = \sum_{i=1}^{m} \frac{t_i}{100000} * 6{,}288 * x_i$$

, kde

i je den a začíná číslem 1 pro aktuální den,

m je počet dní do příští dodávky surovin. Při objednávkách v sobotu na středeční dodávku je $m = 7$ a při objednávkách v úterý na sobotní dodávku je $m = 8$,

t_i je tržba v den i,

x_i je teplota v den i.

3.3.3 Výpočet objednávky surovin

Pomocí vzorců výše vypočítám spotřebu daných surovin a nyní je nutné zařadit tyto výpočty do reálné situace, kdy máme nějaké množství surovin na skladě, v době objednávky je další zboží objednané do předchozí dodávky surovin (stává se tak v úterý při objednávkách na sobotní dodávku), počítá se s transferem suroviny na nebo z jiné restaurace a u suroviny je určitá diference. I když jsou diference standardně velice malé, jejich započítáním do vzorce se zvyšuje přesnost objednávek.

Rezervu budu brát jako polovinu doby od příští dodávky do ukončení doby spotřeby.

U surovin ledový salát, salátová směs a rajčata budu v objednávkách v úterý na sobotní dodávku počítat se rezervou surovin ve výši 0,5dne, protože danému zboží končí datum spotřeby v den další dodávky, tedy ve středu a v objednávkách v sobotu na středeční dodávku budu počítat s rezervou 1 den, protože danému zboží končí doma spotřeby až den po další dodávce, tedy v neděli.

U surovin shake a sundae mléku budu v objednávkách v úterý na sobotní dodávku počítat s rezervou ve výši 2,5 dne, protože danému zboží končí datum spotřeby v neděli další týden, tedy 5 dní od příští dodávky surovin a v objednávkách v sobotu na středeční dodávku budu počítat s rezervou 3 dny, protože danému zboží končí datum spotřeby ve čtvrtek další týden, tedy 6 dní od další dodávky surovin.

Níže jsou výpočty pro dané surovin v jednotlivé termíny dodávky.

Shake mléko

$$O_{sh} = \frac{-p + y_{sh} - d - t - dif + r}{15}$$

, kde

p = počáteční množství na skladě daný den,

y_{sh} = výpočet budoucí spotřeby shake mléka,

d = plánovaná dodávka surovin,

t = plánovaný transfer shake mléka, pokud bude příjem zboží, je číslo kladné, pokud výdej zboží, číslo je záporné,

dif je kladná či záporná diference, kterou zadává profit manažer na základě vývoje inventury,

r je rezerva.

Rezerva pro úterní objednávku na sobotní dodávku se vypočítá následovně:

$$r = \frac{t_{m+1}}{100000} * (0{,}3891 + 0{,}487 * x_{m+1}) + \frac{t_{m+2}}{100000} * (0{,}3891 + 0{,}487 * x_{m+2}) + \frac{\frac{t_{m+3}}{100000} * (0{,}3891 + 0{,}487 * x_{m+3})}{2}$$

, kde

m je počet dní do příští dodávky surovin

t je naplánovaná tržba v daný den v indexu

x je předpověď počasí na daný den v indexu

Rezerva pro sobotní objednávku na středeční dodávku se vypočítá následovně:

$$r = \frac{t_{m+1}}{100000} * (0{,}3891 + 0{,}487 * x_{m+1}) + \frac{t_{m+2}}{100000} * (0{,}3891 + 0{,}487 * x_{m+2}) + \frac{t_{m+3}}{100000} * (0{,}3891 + 0{,}487 * x_{m+3})$$

Výsledek O_{sh} zaokrouhlím nahoru na celé číslo a tím získám počet jednotek zboží, které mám objednat. Pokud vyjde číslo záporné, tato surovina se neobjednává.

Sundae mléko

$$O_{su} = \frac{-p + y_{su} - d - t - dif + r}{15}$$

, kde

p = počáteční množství na skladě daný den,

y_{su} = výpočet budoucí spotřeby sundae mléka,

d = plánovaná dodávka surovin,

t = plánovaný transfer sundae mléka, pokud bude příjem zboží, je číslo kladné, pokud výdej zboží, číslo je záporné,

dif je kladná či záporná diference, kterou zadává profit manažer na základě vývoje inventury,

r je rezerva.

Rezerva pro úterní objednávku na sobotní dodávku se vypočítá následovně:

$$r = \frac{t_{m+1}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+1}) + \frac{t_{m+2}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+2}) + \frac{\frac{t_{m+3}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+3})}{2}$$

, kde

m je počet dní do příští dodávky surovin,

t je naplánovaná tržba v daný den v indexu,

x je předpověď počasí na daný den v indexu.

Rezerva pro sobotní objednávku na středeční dodávku se vypočítá následovně:

$$r = \frac{t_{m+1}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+1}) + \frac{t_{m+2}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+2}) + \frac{t_{m+3}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+3})$$

Výsledek O_{su} zaokrouhlím nahoru na celé číslo a tím získám počet jednotek zboží, které mám objednat. Pokud vyjde číslo záporné, musí profit manažer propočítat objednané množství suroviny ručně, kvůli krátké době spotřeby není možné neobjednat žádné zboží. Pokud se tato situace stává pravidelně, je potřeba přepočítat regresní analýzou koeficienty b_1 a b_2 na základě aktuálních dat.

Ledový salát

$$O_l = -p + y_l - d - t - dif + r$$

, kde

p = počáteční množství na skladě daný den,

y_l = výpočet budoucí spotřeby ledového salátu,

d = plánovaná dodávka surovin,

t = plánovaný transfer ledového salátu, pokud bude příjem zboží, je číslo kladné, pokud výdej zboží, číslo je záporné,

dif je kladná či záporná diference, kterou zadává profit manažer na základě vývoje inventury,

r je rezerva.

Rezerva pro úterní objednávku na sobotní dodávku se vypočítá následovně:

$$r = \frac{\frac{t_{m+1}}{100000} * (12{,}3274 - 0{,}1315 * x_{m+1})}{2}$$

, kde

m je počet dní do příští dodávky surovin,

t je naplánovaná tržba v daný den v indexu,

x je předpověď počasí na daný den v indexu.

Rezerva pro sobotní objednávku na středeční dodávku se vypočítá následovně:

$$r = \frac{t_{m+1}}{100000} * (12{,}3274 - 0{,}1315 * x_{m+1})$$

Výsledek O_l zaokrouhlím nahoru na celé číslo a tím získám počet jednotek zboží, které mám objednat. Pokud vyjde číslo záporné, musí profit manažer propočítat objednané množství suroviny ručně, kvůli krátké době spotřeby není možné neobjednat žádné zboží. Pokud se tato situace stává pravidelně, je potřeba přepočítat regresní analýzou koeficienty b_1 a b_2 na základě aktuálních dat.

Salátová směs

$$O_s = \frac{-p + y_s - d - t - dif + r}{0{,}7}$$

, kde

p = počáteční množství na skladě daný den,

y_s = výpočet budoucí spotřeby salátové směsi,

d = plánovaná dodávka surovin,

t = plánovaný transfer salátově směsi, pokud bude příjem zboží, je číslo kladné, pokud výdej zboží, číslo je záporné,

dif je kladná či záporná diference, kterou zadává profit manažer na základě vývoje inventury,

r je rezerva.

Rezerva pro úterní objednávku na sobotní dodávku se vypočítá následovně:

$$r = \frac{\frac{t_{m+1}}{100000} * (1{,}4241 + 0{,}0545 * x_{m+1})}{2}$$

, kde

m je počet dní do příští dodávky surovin,

t je naplánovaná tržba v daný den v indexu,

x je předpověď počasí na daný den v indexu.

Rezerva pro sobotní objednávku na středeční dodávku se vypočítá následovně:

$$r = \frac{t_{m+1}}{100000} * (12{,}3274 - 0{,}1315 * x_{m+1})$$

Výsledek O_s zaokrouhlím nahoru na celé číslo a tím získám počet jednotek zboží, které mám objednat. Pokud vyjde číslo záporné, musí profit manažer propočítat objednané množství suroviny ručně, kvůli krátké době spotřeby není možné neobjednat žádné zboží. Pokud se tato situace stává pravidelně, je potřeba přepočítat regresní analýzou koeficienty b_1 a b_2 na základě aktuálních dat.

Rajčata

$$O_r = \frac{-p + y_l - d - t - dif + r}{2}$$

, kde

p = počáteční množství na skladě daný den,

y_r = výpočet budoucí spotřeby rajčat,

d = plánovaná dodávka surovin,

t = plánovaný transfer rajčat, pokud bude příjem zboží, je číslo kladné, pokud výdej zboží, číslo je záporné,

dif je kladná či záporná diference, kterou zadává profit manažer na základě vývoje inventury,

r je rezerva.

Rezerva pro úterní objednávku na sobotní dodávku se vypočítá následovně:

$$r = \frac{\frac{t_{m+1}}{100000} * 6{,}288}{2}$$

, kde

m je počet dní do příští dodávky surovin,

t je naplánovaná tržba v daný den v indexu,

x je předpověď počasí na daný den v indexu.

Rezerva pro sobotní objednávku na středeční dodávku se vypočítá následovně:

$$r = \frac{t_{m+1}}{100000} * 6{,}288$$

Výsledek O_r zaokrouhlím nahoru na celé číslo a tím získám počet jednotek zboží, které mám objednat. Pokud vyjde číslo záporné, musí profit manažer propočítat objednané množství suroviny ručně, kvůli krátké době spotřeby není možné neobjednat žádné zboží. Pokud se tato situace stává pravidelně, je potřeba přepočítat průměrnou spotřebu dat.

3.4 Zkouška výpočtů na vstupních datech

Nyní již mám hotové všechny vzorce pro výpočet objednávky těchto surovin. Pro otestování fungování výpočtů provedu pomocí vzorců testování objednávku z úterý dne 12. 9. 2015. Jelikož mám k dispozici údaje o spotřebě surovin i po tomto datu, lehce zjistím, jestli by bylo potřeba nějaké suroviny půjčit nebo některé vyhodit.

3.4.1 Shake mléko

Níže je výpočet budoucí spotřeby shake mléka.

$$y_{sh} = \sum_{i=1}^{7} \frac{t_i}{100000} * (0{,}3891 + 0{,}487 * x_i)$$

$$y_{sh} = 172{,}65$$

Dle výpočtu je do další objednávky potřeba 172,65 litrů shake mléka. Nyní vypočítám, jaké množství bude nutné objednat. Vzorec je níže.

$$O_{sh} = \frac{-p + y_l - d - t - dif + r}{15}$$

Počáteční stav suroviny v den 12.9.2015 je 77 litrů, v dodávce v sobotu dorazí 90 litrů, žádný transfer není naplánovaný a diference není žádná. Nejdříve však vypočítám rezervu.

$$r = \frac{t_{m+1}}{100000} * (0{,}3891 + 0{,}487 * x_{m+1}) + \frac{t_{m+2}}{100000} * (0{,}3891 + 0{,}487 * x_{m+2}) + \frac{t_{m+3}}{100000} * (0{,}3891 + 0{,}487 * x_{m+3})$$

$$r = 68{,}28$$

Rezervu jsem vypočítal ve výši 68,28 litrů a nyní již mohu všechny údaje dosadit do vzorce.

$$O_{sh} = \frac{-77 + 172{,}65 - 90 + 68{,}28}{15} = 4{,}93$$

Po zaokrouhlení na celé číslo nahoru vychází, že máme objednat 5 beden mléka, což je 75 litrů.

V tabulce níže je reálná spotřeba mléka z IS McDonald's den po dni od objednávky. Objednávám dne 12.9.2015 v sobotu na dodávku ve středu 16.9.2015 a suroviny musí vystačit minimálně do 19.9.2015, avšak již žádné nesmí zbýt na konci dne 24.9.2015, protože mléku již konči doba spotřeby.

Den	Začátek dne	Dodávka	Spotřeba	Konec dne
12.9.2015	77	90	27	140
13.9.2015	140	0	35	95
14.9.2015	95	0	22	73
15.9.2015	73	0	22	51
16.9.2015	51	75	21	105
17.9.2015	105	0	25	80
18.9.2015	80	0	26	54
19.9.2015	54	Další dodávka	38	16
20.9.2015	16	0	46	-30

Tabulka 6: Inventura shake mléka
(Zdroj: vlastní zpracování)

Mléko bylo spotřebováno v průběhu dne 20.9.2015, den po další dodávce surovin, vše je tak naprosto v pořádku.

3.4.2 Sundae mléko

Níže je výpočet budoucí spotřeby sundae mléka.

$$y_{su} = \sum_{i=1}^{7} \frac{t_i}{100000} * (3{,}3779 + 0{,}7536 * x_i)$$

$$y_{su} = 307{,}12$$

Dle výpočtu je do další objednávky potřeba 307,12 litrů sundae mléka. Nyní vypočítám, jaké množství bude nutné objednat. Vzorec je níže.

$$O_{su} = \frac{-p + y_l - d - t - dif + r}{15}$$

Počáteční stav suroviny v den 12.9.2015 je 85 litrů, v dodávce v sobotu dorazí 150 litrů, žádný transfer není naplánovaný a diference není žádná. Nejdříve však vypočítám rezervu.

$$r = \frac{t_{m+1}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+1}) + \frac{t_{m+2}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+2}) + \frac{t_{m+3}}{100000} * (3{,}3779 + 0{,}7536 * x_{m+3})$$

$$r = 118{,}44$$

Rezervu jsem vypočítal ve výši 118,44 litrů a nyní již mohu všechny údaje dosadit do vzorce.

$$O_{su} = \frac{-85 + 307{,}12 - 150 + 118{,}44}{15} = 12{,}7$$

Po zaokrouhlení na celé číslo nahoru vychází, že máme objednat 13 beden mléka, což je 195 litrů.

V tabulce níže je reálná spotřeba mléka z IS McDonald's den po dni od objednávky. Objednávám dne 12.9.2015 v sobotu na dodávku ve středu 16.9.2015 a suroviny musí vystačit minimálně do 19.9.2015, avšak již žádné nesmí zbýt na konci dne 24.9.2015, protože mléku již konči doba spotřeby.

Den	**Začátek dne**	**Dodávka**	**Spotřeba**	**Konec dne**
12.9.2015	85	150	70	165
13.9.2015	165	0	95	70
14.9.2015	70	0	28	42
15.9.2015	42	0	25	17
16.9.2015	17	195	37	175
17.9.2015	175	0	55	120
18.9.2015	120	0	50	70
19.9.2015	70	Další dodávka	86	-16

Tabulka 7: Inventura sundae mléka
(Zdroj: vlastní zpracování)

Mléko bylo spotřebováno ke konci dne 19.9.2015, což je den další objednávky surovin, vše je tak naprosto v pořádku.

3.4.3 Ledový salát

Níže je výpočet budoucí spotřeby ledového salátu.

$$y_l = \sum_{i=1}^{7} \frac{t_i}{100000} * (12{,}3274 - 0{,}1315 * x_i)$$

$$y_l = 132{,}36$$

Dle výpočtu je do další objednávky potřeba 132,36 kg ledového salátu. Nyní vypočítám, jaké množství bude nutné objednat. Vzorec je níže.

$$O_l = -p + y_l - d - t - dif + r$$

Počáteční stav suroviny v den 12.9.2015 je 5 kg, v dodávce v sobotu dorazí 90 kg, žádný transfer není naplánovaný a diference není žádná. Nejdříve však vypočítám rezervu.

$$r = \frac{t_{m+1}}{100000} * (12{,}3274 - 0{,}1315 * x_{m+1})$$

$$r = 22{,}69$$

Rezervu jsem vypočítal ve výši 22,69 kg a nyní již mohu všechny údaje dosadit do vzorce.

$$O_l = \frac{-5 + 132{,}36 - 90 + 22{,}69}{15} = 60{,}05$$

Po zaokrouhlení na celé číslo nahoru vychází, že máme objednat 61 sáčků salátu, tedy 61 kg.

V tabulce níže je reálná spotřeba salátu z IS McDonald's den po dni od objednávky. Objednávám dne 12.9.2015 v sobotu na dodávku ve středu 16.9.2015 a suroviny musí vystačit minimálně do 19.9.2015, avšak již žádné nesmí zbýt na konci dne 20.9.2015, protože salátu již konči doba spotřeby.

Den	Začátek dne	Dodávka	Spotřeba	Konec dne
12.9.2015	5	90	25	70
13.9.2015	70	0	26	44
14.9.2015	44	0	14	30
15.9.2015	30	0	15	15
16.9.2015	15	61	16	60
17.9.2015	60	0	20	40
18.9.2015	40	0	26	14
19.9.2015	14	Další dodávka	25	-9

Tabulka 8: Inventura ledového salátu
(Zdroj: vlastní zpracování)

Salát byl spotřebován v průběhu dne 19.9.2015, tedy v den další dodávky, vše je tak naprosto v pořádku.

3.4.4 Salátová směs

Níže je výpočet budoucí spotřeby salátové směsi.

$$y_s = \sum_{i=1}^{7} \frac{t_i}{100000} * (1{,}4241 \ + 0{,}0545 * x_i)$$

$$y_s = 39{,}2$$

Dle výpočtu je do další objednávky potřeba 39,2 kg salátové směsi. Nyní vypočítám, jaké množství bude nutné objednat. Vzorec je níže.

$$O_s = \frac{-p + y_l - d - t - dif + r}{0{,}7}$$

Počáteční stav suroviny v den 12.9.2015 je 6 kg, v dodávce v sobotu dorazí 21 kg, žádný transfer není naplánovaný a diference není žádná. Nejdříve však vypočítám rezervu.

$$r = \frac{t_{m+1}}{100000} * (1{,}4241 \ + 0{,}0545 * x_{m+1})$$

$$r = 6{,}53$$

Rezervu jsem vypočítal ve výši 4,09 kg a nyní již mohu všechny údaje dosadit do vzorce.

$$O_s = \frac{-6 + 39{,}2 - 21 + 6{,}53}{0{,}7} = 18{,}73$$

Po zaokrouhlení na celé číslo nahoru vychází, že máme objednat 19 sáčků salátu, tedy 13,3 kg.

V tabulce níže je reálná spotřeba salátu z IS McDonald's den po dni od objednávky. Objednávám dne 12.9.2015 v sobotu na dodávku ve středu 16.9.2015 a suroviny musí vystačit minimálně do 19.9.2015, avšak již žádné nesmí zbýt na konci dne 20.9.2015, protože salátu již konči doba spotřeby.

Den	**Začátek dne**	**Dodávka**	**Spotřeba**	**Konec dne**
12.9.2015	6	21	8	19
13.9.2015	19	0	5	14
14.9.2015	14	0	4	10
15.9.2015	10	0	6	4
16.9.2015	4	13,3	5	12,3
17.9.2015	12,3	0	5	7,3
18.9.2015	7,3	0	6	1,3
19.9.2015	1,3	Další dodávka	8	-6,7

Tabulka 9: Inventura salátové směsi
(Zdroj: vlastní zpracování)

Salát byl spotřebován v průběhu dne 19.9.2015, tedy v den další dodávky, vše je tak naprosto v pořádku.

3.4.5 Rajčata

Níže je výpočet budoucí spotřeby salátové směsi.

$$y_r = \sum_{i=1}^{7} \frac{t_i}{100000} * 6{,}288$$

$$y_r = 90{,}52$$

Dle výpočtu je do další objednávky potřeba 60,52 kg rajčat. Nyní vypočítám, jaké množství bude nutné objednat. Vzorec je níže.

$$O_r = \frac{-p + y_l - d - t - dif + r}{2}$$

Počáteční stav suroviny v den 12.9.2015 je 8 kg, v dodávce v sobotu dorazí 60 kg, žádný transfer není naplánovaný a diference není žádná. Nejdříve však vypočítám rezervu.

$$r = \frac{t_{m+1}}{100000} * 6{,}288$$

$$r = 15{,}34$$

Rezervu jsem vypočítal ve výši 15,34 kg a nyní již mohu všechny údaje dosadit do vzorce.

$$O_r = \frac{-8 + 90{,}52 - 40 + 15{,}34}{2} = 28{,}93$$

Po zaokrouhlení na celé číslo nahoru vychází, že máme objednat 29 sáčků rajčat, tedy 58 kg.

V tabulce níže je reálná spotřeba salátu z IS McDonald's den po dni od objednávky. Objednávám dne 12.9.2015 v sobotu na dodávku ve středu 16.9.2015 a suroviny musí vystačit minimálně do 19.9.2015, avšak již žádné nesmí zbýt na konci dne 20.9.2015, protože salátu již konči doba spotřeby.

Den	**Začátek dne**	**Dodávka**	**Spotřeba**	**Konec dne**
12.9.2015	8	60	19	49
13.9.2015	49	0	18	31
14.9.2015	31	0	12	19
15.9.2015	19	0	14	5
16.9.2015	5	58	15	48
17.9.2015	48	0	15	33
18.9.2015	33	0	19	14
19.9.2015	14	Další dodávka	17	-3

Tabulka 10: Inventura rajčat
(Zdroj: vlastní zpracování)

Rajčata budou spotřebována v průběhu dne 19.9.2015, tedy v den další dodávky, vše je tak naprosto v pořádku.

3.5 Snižování nákladů

Zkušební výpočet teoretické objednávky surovin v průběhu září dopadl tak, že by se žádný salát nemusel půjčovat, ani vyhazovat. Nyní se podíváme na aktuální náklady firmy při špatném objednávání.

Z interních dokumentů bylo zjištěno, že se za období červenec – září 2015 muselo celkem patnáct krát zajišťovat zboží, které chybělo a celkem bylo vyhozeno prošlé zboží za 50 000Kč.

Náklad na zajištění zboží se skládá ze mzdy manažera, který musí zboží na nějaké restauraci zajistit, mzda člověka, co zboží musí přivést a posléze zase vrátit, pohonné hmoty a opotřebení auta. Celkem se jedná přibližně o 1000Kč na jedno zapůjčení, v září 2015 tato položka čítala přibližně 15 000Kč.

Za měsíc náklady za špatné objednání chlazených surovin dosahují přibližně 65 tisíc Kč. V případě využívání statistických metod při objednávání se tak ročně může ušetřit částka přibližně 780 000Kč.

3.6 Program v Excelu

Jedním z cílů této diplomové práce, je poskytnou manažerům lehce ovladatelný program na objednávku chlazených surovin. Ovládání musí být maximálně jednoduché a intuitivní.

Po otevření souboru se zobrazí pouze úvodní tabulka, samotný sešit včetně prostředí Excelu se skryje.

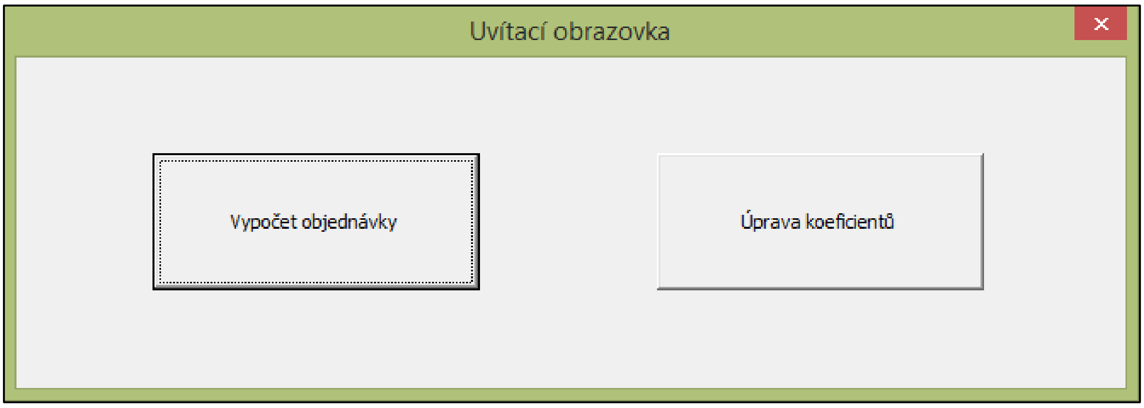

Obrázek 46: Úvodní obrazovka programu
Zdroj: (vlastní zpracování)

Na úvodní tabulce je na výběr výpočet objednávky a úprava koeficientů, která se používá při přepočítání koeficientu pomocí regresní přímky. Náhled tabulky je níže.

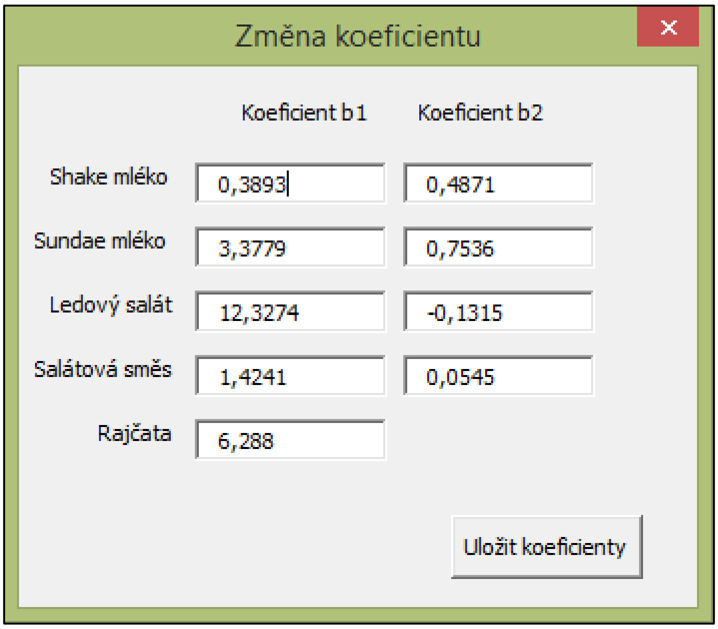

Obrázek 47: Změna koeficientu v programu
Zdroj: (vlastní zpracování)

Hodnoty koeficientu se zde zobrazí již předvyplněné a stačí je upravit a uložit. Možnost výpočet objednávky v úvodní tabulce zobrazí možnost propočtu jednotlivých surovin a zadání naplánované tržby a předpovědi počasí.

Obrázek 48: Tabulka pro výpočet objednávky
Zdroj: (vlastní zpracování)

Po vstoupení do této tabulky je nutné před samotným výpočtem vložit naplánovanou tržbu a předpověď počasí.

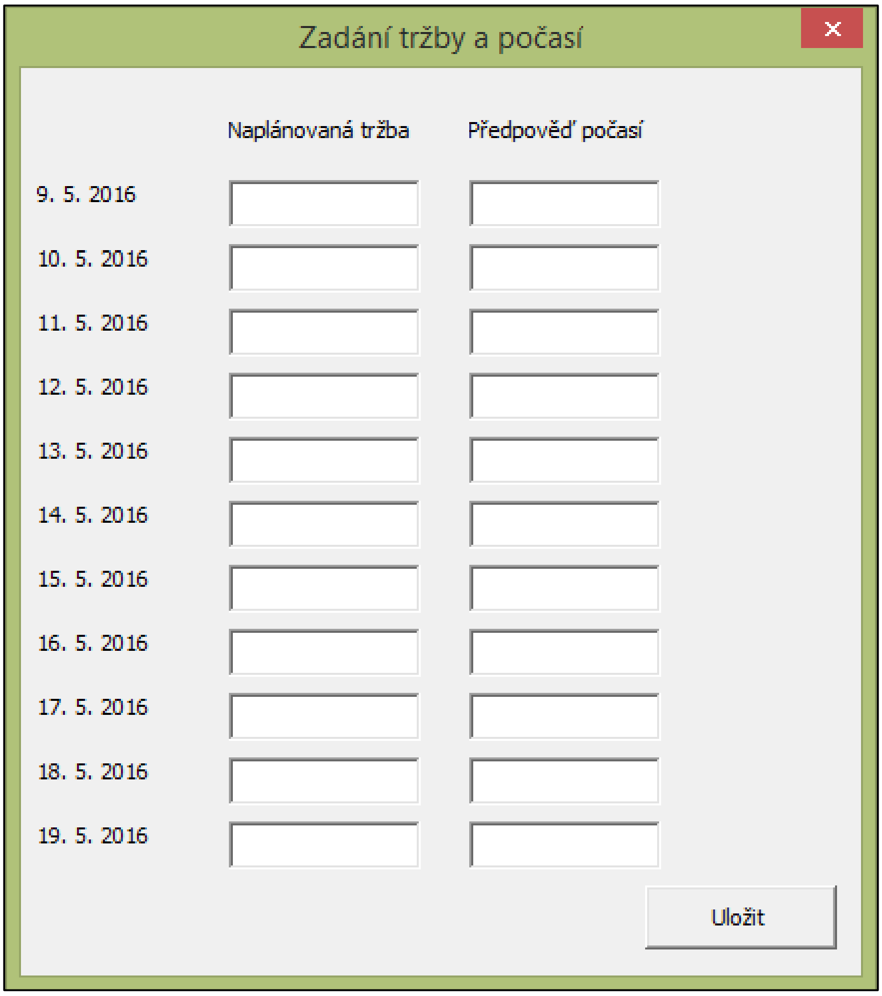

Obrázek 49: Vložení tržby a počasí
Zdroj: (vlastní zpracování)

Datum se v této tabulce mění automaticky dle aktuálního dne. Mezi rámečky pro vložení dat se dá lehce přepínat tabulátorem a kurzor se mění po sloupcích směrem dolů. Toto nastavení výrazně urychlí vložení vstupních dat pro výpočty. Jelikož se hodnoty ukládají do sešitu, při využití programu v ten samý den není třeba zadávat tyto data znovu.

Níže je tabulka pro výpočet shake mléka.

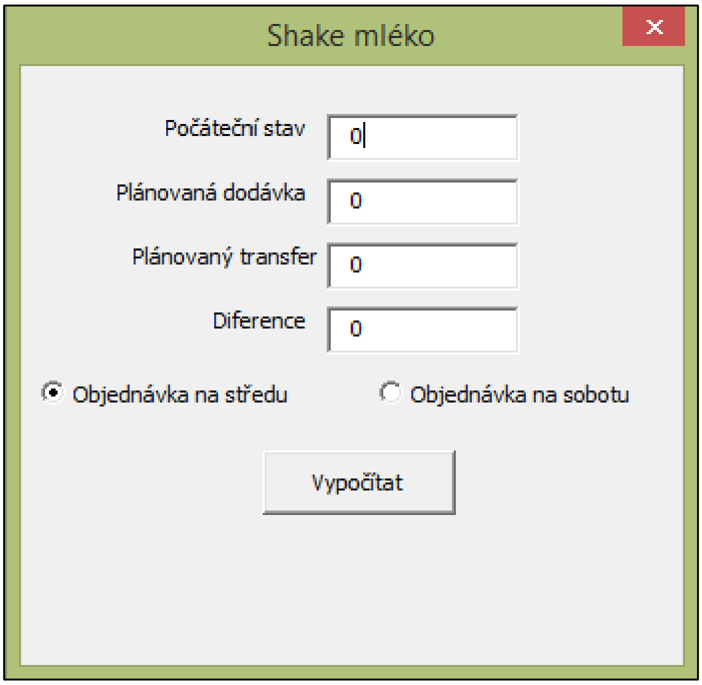

Obrázek 50: Výpočet suroviny
Zdroj: (vlastní zpracování)

Do této tabulky se vloží počáteční stav suroviny v daný den z informačního systému, poté množství suroviny, které je objednané do dřívější dodávky a případně plánovaný tranfer suroviny do nebo z jiné restaurace a diference, pokud ji profit manažer uzná jako důležitou pro správný výpočet.

Poté stačí určit, na který den se objednávka dělá a stisknout tlačítko pro výpočet.

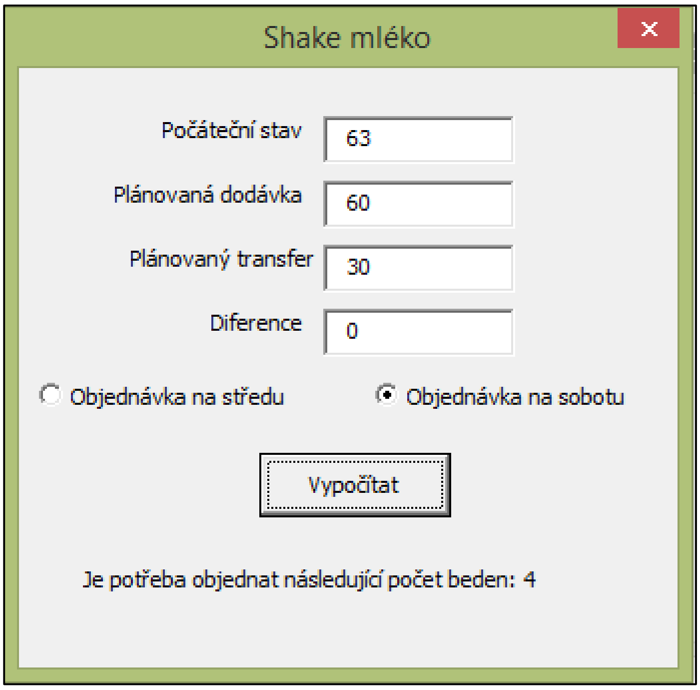

Obrázek 51: Provedený výpočet suroviny
Zdroj: (vlastní zpracování)

Po proběhnutí výpočtu se v textu níže zobrazí množství surovin, které se má objednat. Pokud výpočet proběhne záporný, tedy že není potřeba objednat žádné množství, vyskočí chybová hláška s upozorněním a žádostí o ruční propočet, případně přepočítání koeficientů regresní přímky.

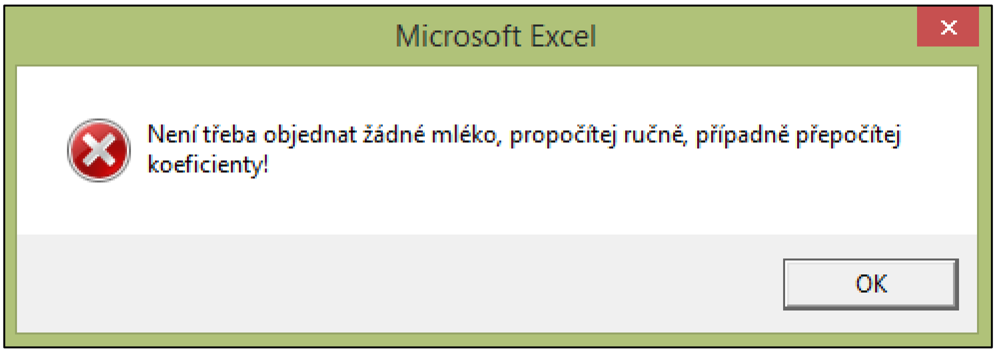

Obrázek 52: Chybová hláška v programu
Zdroj: (vlastní zpracování)

Stejně probíhá i výpočet dalších surovin. Po zavření úvodní tabulky se sešit automaticky uloží, pro uchování případných změn koeficientů a uložení naplánované tržby a předpovědi počasí pro případné využití v ten samý den, a zavře. Uživatel tak vůbec nepřichází ke styku s prostředím Excelu, ale pouze s tabulkami.

ZÁVĚR

Cílem práce bylo zjistit souvislost mezi teplotou a spotřebou chlazených surovin a vytvořit takový algoritmus, který optimalizuje objednávání tohoto zboží.

V teoretické části jsou zahrnuty všechny statistické metody, které používám v dalších částech.

V analýze problému jsem nejprve zjišťoval normalitu dat. Data však nejsou normálního rozdělení, a tak jsem musel použít neparametrické statistické metody. Zjistil korelaci pomocí Kendallova tau mezi venkovní teplotou a spotřebou všech surovin, kromě rajčat. V návrhu řešení jsem nejdříve ověřil, že rozdíl naplánované a reálné tržby je statisticky nevýznamný a také, že rozdíl mezi předpovědí počasí a reálnou teplotou je statisticky nevýznamný. Poté jsem proložil spotřeby všech surovin, až na rajčata, regresní přímkou. U rajčat byly spotřeby této suroviny pouze zprůměrovány. Tímto jsem získal očekávanou spotřebu suroviny při dané teplotě.

Navrhnul jsem algoritmus, který na základě předpovědi počasí a naplánované tržby vypočítá předpokládanou spotřebu do dalšího objednávkového cyklu. Na dostupných datech jsem si také ověřil přesnost tohoto algoritmu.

A nakonec jsem vytvořil program, který lze jednoduše využít přímo na restauracích a optimalizovat tak objednávky.

Byla zjištěna roční úspora na nákladech na restauraci Rohlenka až 780 000Kč ročně, což dělá v systému 8 restaurací pod naší firmou úsporu milionů ročně a v rámci celého systému McDonald's ČR desítky milionů.

LITERATURA

1) KROPÁČ, J. *Statistika A*. 4. vyd. Brno: FP VUT, 2011, 140 s. ISBN 978-80-214-4226-9

2) Pravděpodobnostní rozdělení spojité náhodné veličiny pro základní soubory. *Statistika a výpočetní technika.* [online]. ©2012 [cit. 2016-05-10]. Dostupné z:http://cit.vfu.cz/statpotr/POTR/Teorie/Predn2/rozdelZS.htm

3) BOHÁČKOVÁ, J. *Testy statistických hypotéz založené na empirických distribučních funkcích*. Brno, 2009. Diplomová práce. Masarykova Univerzita, Přírodovědecká fakulta.

4) KROPÁČ, J. *Statistika B*. 3. vyd. Brno: Akademické nakladatelství CERM, 2012. 152 s. ISBN 978-80-7204-822-9

5) HENDL, J. *Přehled statistických metod.* 4. vyd. Praha: Portál s.r.o., 2012. 736s. ISBN 978-80-262-0200-4

6) t-test. *Statistika a výpočetní technika.* [online]. ©2012 [cit. 2016-05-10]. Dostupné z: http://cit.vfu.cz/statpotr/POTR/Teorie/Predn3/ttest.htm

7) Wilcoxon. *Statistika a výpočetní technika.* [online]. ©2012 [cit. 2016-05-10]. Dostupné z: http://cit.vfu.cz/statpotr/POTR/Teorie/Predn4/Wilcoxon.htm

8) Přispěvatelé Wikipedie, *M-Palác* [online]. Wikipedie: Otevřená encyklopedie, ©2013 [cit. 2015-05-08]. Dostupné z: http://cs.wikipedia.org/w/index.php?title=MPal%C3%A1c

9) Přispěvatelé Wikipedie, *Avion Shopping Park Brno* [online], Wikipedie: Otevřená encyklopedie, ©2013 [cit. 2015-05-08]. Dostupné z: http://cs.wikipedia.org/w/index.php?title=Avion_Shopping_Park_Brno

10) Přispěvatelé Wikipedie, *Olympia Brno* [online]. Wikipedie: Otevřená encyklopedie, ©2013 [cit. 2015-05-08]. Dostupné z:

http://cs.wikipedia.org/w/index.php?title=Olympia_Brno&oldid=11000264

11) MAFRA A.S.. McDonald's v Brně-Líšni zkrachoval. *Zprávy iDnes.cz* [online]. ©1999-2014 [cit. 2016-05-08]. Dostupné z: http://zpravy.idnes.cz/mcdonalds-v-brnelisni-zkrachoval-dlt-/domaci.aspx?c=A011011_173218_brno_zpravy_boh

12) ČTK. McDonald's Česká Republika otevírá novou restauraci McDonald's v Brně. *protext.cz* [online]. ©2011 [cit. 2016-05-08]. Dostupné z:http://www.protext.cz/english/zprava.php?id=9665

13) What does WRIN stand for?. *Abbreviations.com.* [online]. ©2001-2016 [cit. 2016-05-10]. Dostupné z: http://www.abbreviations.com/WRIN

14) Stanice – Brno, aktuální teplota, rekordy, archiv, průměry. *In-počasí.* [online]. ©2015 [cit. 2016-05-10]. Dostupné z: http://www.in-pocasi.cz/archiv/stanice.php?stanice=brno&historie_bar_mesic=7&historie_bar_rok=2015&typ=teplota

SEZNAM TABULEK

SEZNAM OBRÁZKŮ

SEZNAM PŘÍLOH

Příloha 1 – Tabulka dat pro všechny dny

n	Den	Teplota	SH_přep	SU_přep	Sal_přep	Mix_Přep	Rajč_přep
1	1.7.2015	28	15,84	26,22	7,65	3,82	6,01
2	2.7.2015	29	15,55	30,07	7,78	3,11	5,70
3	3.7.2015	31	19,21	31,61	7,60	3,60	5,60
4	4.7.2015	33	16,82	33,63	6,86	3,43	5,15
5	5.7.2015	35	17,48	37,51	6,92	4,01	5,46
6	6.7.2015	34	23,45	28,79	6,99	4,11	5,76
7	7.7.2015	35	26,27	35,43	7,33	5,50	6,11
8	8.7.2015	29	9,97	30,44	8,40	3,15	6,30
9	9.7.2015	25	10,08	22,08	7,68	3,36	5,76
10	10.7.2015	23	11,50	26,06	8,05	3,07	6,51
11	11.7.2015	25	13,24	26,49	7,33	2,82	5,35
12	12.7.2015	31	18,57	33,25	7,19	3,00	5,69
13	13.7.2015	24	14,95	20,25	7,71	2,89	5,79
14	14.7.2015	27	12,23	20,75	7,98	2,66	6,38
15	15.7.2015	27	15,11	24,08	8,97	2,83	7,55
16	16.7.2015	31	15,99	31,98	7,99	3,55	7,11
17	17.7.2015	35	17,89	26,06	8,95	4,28	6,61
18	18.7.2015	35	16,95	28,16	8,05	3,74	6,03
19	19.7.2015	35	17,06	31,01	7,75	3,10	5,27
20	20.7.2015	30	15,07	24,95	8,32	3,12	6,76
21	21.7.2015	34	17,76	34,04	7,40	3,95	6,41
22	22.7.2015	36	16,01	32,53	8,51	3,50	7,01
23	23.7.2015	30	14,49	25,71	8,41	2,80	7,01
24	24.7.2015	34	14,57	28,78	8,01	3,64	6,92
25	25.7.2015	31	15,84	29,64	8,18	3,07	6,13
26	26.7.2015	25	14,34	35,05	7,43	2,12	5,31
27	27.7.2015	21	8,27	17,38	9,10	3,31	6,62

28	28.7.2015	27	13,96	21,82	9,60	3,49	6,98
29	29.7.2015	23	14,50	22,18	8,53	3,41	5,97
30	30.7.2015	24	11,43	24,50	8,17	3,27	5,72
31	31.7.2015	25	15,30	27,42	8,93	2,55	5,74
32	1.8.2015	28	13,15	30,36	7,59	3,54	6,58
33	2.8.2015	25	12,49	21,01	7,95	2,27	6,25
34	3.8.2015	31	14,42	33,33	8,11	3,60	5,41
35	4.8.2015	32	20,04	29,54	8,44	3,16	5,27
36	5.8.2015	33	15,97	27,45	7,98	2,99	6,49
37	6.8.2015	35	15,40	25,67	8,13	3,00	6,42
38	7.8.2015	36	18,13	28,35	8,24	2,97	6,59
39	8.8.2015	36	19,26	29,82	7,45	3,11	6,21
40	9.8.2015	36	21,43	32,90	6,94	3,02	6,04
41	10.8.2015	35	15,80	27,76	8,14	2,39	5,74
42	11.8.2015	36	14,89	26,05	8,37	3,26	6,51
43	12.8.2015	36	15,47	21,92	8,17	3,44	6,45
44	13.8.2015	35	18,63	25,48	8,37	2,28	6,08
45	14.8.2015	36	17,46	23,07	7,79	3,12	6,55
46	15.8.2015	33	18,53	23,02	8,14	2,53	6,46
47	16.8.2015	30	15,84	24,58	8,19	3,00	6,55
48	17.8.2015	22	10,87	14,04	7,70	2,26	6,34
49	18.8.2015	17	9,54	12,72	8,63	2,73	6,36
50	19.8.2015	19	10,94	14,00	8,31	3,50	6,13
51	20.8.2015	24	11,88	19,54	8,05	2,68	6,13
52	21.8.2015	25	10,64	21,97	8,24	2,40	6,52
53	22.8.2015	25	13,27	22,02	7,54	2,41	5,43
54	23.8.2015	24	10,00	22,63	8,16	2,63	5,79
55	24.8.2015	27	11,33	16,74	8,37	2,95	6,40
56	25.8.2015	23	8,40	15,47	8,84	2,65	6,63

57	26.8.2015	26	12,55	21,07	8,52	3,59	6,28
58	27.8.2015	28	12,59	21,41	7,98	2,52	5,88
59	28.8.2015	30	12,06	19,30	8,27	2,76	6,55
60	29.8.2015	31	14,66	28,02	7,82	2,28	6,52
61	30.8.2015	34	15,51	32,42	7,61	3,10	5,36
62	31.8.2015	34	14,81	24,86	7,93	3,17	6,35
63	1.9.2015	32	14,36	26,32	8,38	2,39	7,18
64	2.9.2015	22	11,52	13,95	9,10	3,03	6,67
65	3.9.2015	23	8,43	16,85	8,43	3,01	6,62
66	4.9.2015	23	11,81	18,14	8,44	2,53	6,33
67	5.9.2015	21	11,25	20,00	8,33	2,08	6,25
68	6.9.2015	17	10,28	19,43	8,38	1,90	6,86
69	7.9.2015	16	7,97	12,63	9,97	2,66	7,31
70	8.9.2015	18	9,86	17,25	9,86	2,46	6,16
71	9.9.2015	16	7,29	13,55	11,46	2,61	6,25
72	10.9.2015	20	9,56	16,38	12,74	1,82	6,37
73	11.9.2015	17	9,27	16,76	11,05	1,78	6,06
74	12.9.2015	22	8,56	22,19	10,46	2,54	6,02
75	13.9.2015	24	11,14	30,24	10,82	1,59	5,73
76	14.9.2015	24	11,81	15,03	12,35	2,15	6,44
77	15.9.2015	22	11,04	12,55	11,54	3,01	7,03
78	16.9.2015	27	10,39	18,30	11,87	2,47	7,42
79	17.9.2015	31	11,10	24,41	11,10	2,66	6,66
80	18.9.2015	20	8,74	16,82	11,44	2,02	6,39
81	19.9.2015	24	12,25	27,72	10,64	2,58	5,48
82	20.9.2015	20	14,04	24,41	11,29	2,14	5,49
83	21.9.2015	18	10,20	15,61	11,40	1,80	6,00
84	22.9.2015	21	8,48	14,46	12,96	1,50	5,48
85	23.9.2015	20	8,82	15,99	11,58	1,65	6,62

86	24.9.2015	20	10,95	18,56	11,90	2,86	6,19
87	25.9.2015	18	6,99	13,98	10,84	3,15	5,94
88	26.9.2015	16	9,93	20,21	10,62	2,40	5,48
89	27.9.2015	17	9,80	24,32	11,25	2,54	5,44
90	28.9.2015	17	10,67	23,54	9,19	2,57	8,09
91	29.9.2015	17	9,75	13,65	8,45	1,95	9,10
92	30.9.2015	14	6,95	9,43	8,44	2,98	8,44

Příloha 2 – Tabulka dat pro pracovní dny

n	Den	Teplota	SH_přep	SU_přep	Sal_přep	Mix_Přep	Rajč_přep
1	1.7.2015	28	15,84	26,22	7,65	3,82	6,01
2	2.7.2015	29	15,55	30,07	7,78	3,11	5,70
3	6.7.2015	34	23,45	28,79	6,99	4,11	5,76
4	7.7.2015	35	26,27	35,43	7,33	5,50	6,11
5	8.7.2015	29	9,97	30,44	8,40	3,15	6,30
6	9.7.2015	25	10,08	22,08	7,68	3,36	5,76
7	13.7.2015	24	14,95	20,25	7,71	2,89	5,79
8	14.7.2015	27	12,23	20,75	7,98	2,66	6,38
9	15.7.2015	27	15,11	24,08	8,97	2,83	7,55
10	16.7.2015	31	15,99	31,98	7,99	3,55	7,11
11	20.7.2015	30	15,07	24,95	8,32	3,12	6,76
12	21.7.2015	34	17,76	34,04	7,40	3,95	6,41
13	22.7.2015	36	16,01	32,53	8,51	3,50	7,01
14	23.7.2015	30	14,49	25,71	8,41	2,80	7,01
15	27.7.2015	21	8,27	17,38	9,10	3,31	6,62
16	28.7.2015	27	13,96	21,82	9,60	3,49	6,98

17	29.7.2015	23	14,50	22,18	8,53	3,41	5,97
18	30.7.2015	24	11,43	24,50	8,17	3,27	5,72
19	3.8.2015	31	14,42	33,33	8,11	3,60	5,41
20	4.8.2015	32	20,04	29,54	8,44	3,16	5,27
21	5.8.2015	33	15,97	27,45	7,98	2,99	6,49
22	6.8.2015	35	15,40	25,67	8,13	3,00	6,42
23	10.8.2015	35	15,80	27,76	8,14	2,39	5,74
24	11.8.2015	36	14,89	26,05	8,37	3,26	6,51
25	12.8.2015	36	15,47	21,92	8,17	3,44	6,45
26	13.8.2015	35	18,63	25,48	8,37	2,28	6,08
27	17.8.2015	22	10,87	14,04	7,70	2,26	6,34
28	18.8.2015	17	9,54	12,72	8,63	2,73	6,36
29	19.8.2015	19	10,94	14,00	8,31	3,50	6,13
30	20.8.2015	24	11,88	19,54	8,05	2,68	6,13
31	24.8.2015	27	11,33	16,74	8,37	2,95	6,40
32	25.8.2015	23	8,40	15,47	8,84	2,65	6,63
33	26.8.2015	26	12,55	21,07	8,52	3,59	6,28

34	27.8.2015	28	12,59	21,41	7,98	2,52	5,88
35	31.8.2015	34	14,81	24,86	7,93	3,17	6,35
36	1.9.2015	32	14,36	26,32	8,38	2,39	7,18
37	2.9.2015	22	11,52	13,95	9,10	3,03	6,67
38	3.9.2015	23	8,43	16,85	8,43	3,01	6,62
39	7.9.2015	16	7,97	12,63	9,97	2,66	7,31
40	8.9.2015	18	9,86	17,25	9,86	2,46	6,16
41	9.9.2015	16	7,29	13,55	11,46	2,61	6,25
42	10.9.2015	20	9,56	16,38	12,74	1,82	6,37
43	14.9.2015	24	11,81	15,03	12,35	2,15	6,44
44	15.9.2015	22	11,04	12,55	11,54	3,01	7,03
45	16.9.2015	27	10,39	18,30	11,87	2,47	7,42
46	17.9.2015	31	11,10	24,41	11,10	2,66	6,66
47	21.9.2015	18	10,20	15,61	11,40	1,80	6,00
48	22.9.2015	21	8,48	14,46	12,96	1,50	5,48
49	23.9.2015	20	8,82	15,99	11,58	1,65	6,62
50	24.9.2015	20	10,95	18,56	11,90	2,86	6,19
51	29.9.2015	17	9,75	13,65	8,45	1,95	9,10

52	30.9.2015	14	6,95	9,43	8,44	2,98	8,44

Příloha 3 – Tabulka dat pro víkendy

n	Den	Teplota	SH_přep	SU_přep	Sal_přep	Mix_Přep	Rajč_přep
1	3.7.2015	31	19,21	31,61	7,60	3,60	5,60
2	4.7.2015	33	16,82	33,63	6,86	3,43	5,15
3	5.7.2015	35	17,48	37,51	6,92	4,01	5,46
4	10.7.2015	22	11,50	26,06	8,05	3,07	6,51
5	11.7.2015	25	13,24	26,49	7,33	2,82	5,35
6	12.7.2015	31	18,57	33,25	7,19	3,00	5,69
7	17.7.2015	35	17,89	26,06	8,95	4,28	6,61
8	18.7.2015	35	16,95	28,16	8,05	3,74	6,03
9	19.7.2015	35	17,06	31,01	7,75	3,10	5,27
10	24.7.2015	34	14,57	28,78	8,01	3,64	6,92
11	25.7.2015	31	15,84	29,64	8,18	3,07	6,13
12	26.7.2015	25	14,34	35,05	7,43	2,12	5,31
13	31.7.2015	25	15,30	27,42	8,93	2,55	5,74
14	1.8.2015	28	13,15	30,36	7,59	3,54	6,58
15	2.8.2015	25	12,49	21,01	7,95	2,27	6,25
16	7.8.2015	36	18,13	28,35	8,24	2,97	6,59
17	8.8.2015	36	19,26	29,82	7,45	3,11	6,21

18	9.8.2015	36	21,43	32,90	6,94	3,02	6,04
19	14.8.2015	36	17,46	23,07	7,79	3,12	6,55
20	15.8.2015	33	18,53	23,02	8,14	2,53	6,46
21	16.8.2015	30	15,84	24,58	8,19	3,00	6,55
22	21.8.2015	25	10,64	21,97	8,24	2,40	6,52
23	22.8.2015	25	13,27	22,02	7,54	2,41	5,43
24	23.8.2015	24	10,00	22,63	8,16	2,63	5,79
25	28.8.2015	30	12,06	19,30	8,27	2,76	6,55
26	29.8.2015	31	14,66	28,02	7,82	2,28	6,52
27	30.8.2015	34	15,51	32,42	7,61	3,10	5,36
28	4.9.2015	23	11,81	18,14	8,44	2,53	6,33
29	5.9.2015	21	11,25	20,00	8,33	2,08	6,25
30	6.9.2015	17	10,28	19,43	8,38	1,90	6,86
31	11.9.2015	17	9,27	16,76	11,05	1,78	6,06
32	12.9.2015	22	8,56	22,19	10,46	2,54	6,02
33	13.9.2015	24	11,14	30,24	10,82	1,59	5,73
34	18.9.2015	20	8,74	16,82	11,44	2,02	6,39

35	19.9.2015	24	12,25	27,72	10,64	2,58	5,48
36	20.9.2015	20	14,04	24,41	11,29	2,14	5,49
37	25.9.2015	18	6,99	13,98	10,84	3,15	5,94
38	26.9.2015	16	9,93	20,21	10,62	2,40	5,48
39	27.9.2015	17	9,80	24,32	11,25	2,54	5,44
40	28.9.2015	17	10,67	23,54	9,19	2,57	8,09

Příloha 4 – Tabulka dat pro počasí

n	Den	Teplota předpověď	Reálná teplota
1	1.7.2015	27	28
2	2.7.2015	30	29
3	3.7.2015	34	31
4	4.7.2015	34	33
5	5.7.2015	35	35
6	6.7.2015	34	34
7	7.7.2015	34	35
8	8.7.2015	31	29
9	9.7.2015	27	25
10	10.7.2015	23	22
11	11.7.2015	26	25
12	12.7.2015	31	31
13	13.7.2015	25	24
14	14.7.2015	28	27
15	15.7.2015	28	27
16	16.7.2015	30	31
17	17.7.2015	33	35
18	18.7.2015	35	35
19	19.7.2015	34	35
20	20.7.2015	31	30
21	21.7.2015	35	34
22	22.7.2015	34	36
23	23.7.2015	30	30
24	24.7.2015	33	34
25	25.7.2015	30	31
26	26.7.2015	24	25
27	27.7.2015	19	21
28	28.7.2015	26	27
29	29.7.2015	23	23
30	30.7.2015	25	24
31	31.7.2015	26	25
32	1.8.2015	30	28
33	2.8.2015	26	25
34	3.8.2015	30	31
35	4.8.2015	31	32
36	5.8.2015	34	33
37	6.8.2015	36	35
38	7.8.2015	36	36
39	8.8.2015	37	36

40	9.8.2015	36	36
41	10.8.2015	35	35
42	11.8.2015	35	36
43	12.8.2015	35	36
44	13.8.2015	35	35
45	14.8.2015	36	36
46	15.8.2015	31	33
47	16.8.2015	28	30
48	17.8.2015	20	22
49	18.8.2015	17	17
50	19.8.2015	18	19
51	20.8.2015	25	24
52	21.8.2015	26	25
53	22.8.2015	25	25
54	23.8.2015	26	24
55	24.8.2015	28	27
56	25.8.2015	22	23
57	26.8.2015	26	26
58	27.8.2015	26	28
59	28.8.2015	32	30
60	29.8.2015	32	31
61	30.8.2015	35	34
62	31.8.2015	34	34
63	1.9.2015	33	32
64	2.9.2015	20	22
65	3.9.2015	22	23
66	4.9.2015	21	23
67	5.9.2015	20	21
68	6.9.2015	20	17
69	7.9.2015	15	16
70	8.9.2015	17	18
71	9.9.2015	17	16
72	10.9.2015	22	20
73	11.9.2015	18	17
74	12.9.2015	22	22
75	13.9.2015	25	24
76	14.9.2015	26	24
77	15.9.2015	20	22
78	16.9.2015	25	27
79	17.9.2015	30	31
80	18.9.2015	20	20
81	19.9.2015	23	24
82	20.9.2015	19	20

83	21.9.2015	19	18
84	22.9.2015	19	21
85	23.9.2015	22	20
86	24.9.2015	21	20
87	25.9.2015	17	18
88	26.9.2015	15	16
89	27.9.2015	16	17
90	28.9.2015	15	17
91	29.9.2015	16	17
92	30.9.2015	15	14